

PERBANDINGAN KINERJA ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK PADA DETEKSI MALARIA MENGGUNAKAN CITRA SEL DARAH

Agung Wahyu Setiawan*¹

¹Institut Teknologi Bandung, Bandung
Email: ¹agungws@gmail.com

*Penulis Korespondensi

(Naskah masuk: 22 November 2023, diterima untuk diterbitkan: 20 Juni 2025)

Abstrak

Malaria masih menjadi salah satu penyebab kematian tertinggi di dunia, terutama di daerah yang berstatus endemi. Standar emas penegakan diagnosis malaria adalah berbasis citra apusan atau sel darah yang diperoleh dengan menggunakan mikroskop. Kendala utama dalam penegakan diagnosis ini adalah kurangnya tenaga ahli untuk melakukan asesmen citra sel darah. Oleh karena itu, dilakukan diagnosis malaria berbasis citra sel darah menggunakan *Artificial Intelligent* (AI) / kecerdasan buatan. Deteksi malaria berbasis AI yang dilakukan pada studi-studi sebelumnya telah menghasilkan kinerja yang sudah baik. Namun, kinerja deteksi ini masih dapat ditingkatkan. Studi ini menggunakan 27.558 citra sel darah yang terdiri dari 13.779 sel darah terinfeksi dan 13.779 tidak terinfeksi. Citra-citra sel darah ini dibagi menjadi tiga kelompok, yaitu pelatihan (80%); validasi (10%); dan pengujian (10%). Pada studi ini, digunakan ResNet50; ResNet101; ResNet152; ResNet50V2; ResNet101V2; ResNet152V2; DenseNet121; DenseNet169; DenseNet201; InceptionV3; InceptionResNetV2; VGG16; VGG19; dan MobileNetV2. Tujuan utama dari studi ini adalah mencari arsitektur CNN yang memiliki kinerja terbaik dalam deteksi malaria berbasis citra sel darah. Perbandingan kinerja diases dengan menggunakan nilai akurasi, sensitivitas, spesifisitas, skor F1, dan *Area Under the Curve* (AUC). Arsitektur MobileNetV2 memberikan kinerja paling baik dengan nilai rata-rata pelatihan, validasi, dan pengujian tertinggi. Nilai rata-rata akurasi mencapai 97,68%; spesifisitas 98,61%; sensitivitas 96,75%; Skor F1 97,70%; dan AUC sebesar 99,65%. Selain itu, waktu pembuatan model arsitektur MobileNetV2 hanya sekitar 2,5 jam. Selain itu, jumlah lapisan *convolutional* tidak memengaruhi kinerja deteksi malaria. Dengan lapisan *convolutional* berjumlah 53, MobileNetV2 berkinerja lebih baik dibandingkan dengan arsitektur-arsitektur lain dengan jumlah lapisan *convolutional* lebih banyak.

Kata kunci: citra sel darah, deteksi, kecerdasan buatan, malaria, mobilenetv2

COMPARISON OF PERFORMANCE OF CONVOLUTIONAL NEURAL NETWORKS ARCHITECTURES ON MALARIA DETECTION USING BLOOD CELL IMAGE

Abstract

Malaria is still one of the highest causes of death in the world, especially in the endemic areas. The gold standard for diagnosing malaria is based on smears blood smears or cells image which is obtained using a microscope. The main challenge in detecting malaria is the lack of experts to assess the blood smears. Therefore, the detection is carried out using *Artificial Intelligence* (AI). Previous studies that used AI to detect malaria have a good performance. However, the detection performance can still be improved. Furthermore, previous studies only used one or two or three performance metrics. This study used 27,558 blood cell images consisting of 13,779 infected and 13,779 uninfected blood cells. These blood cell images are divided into three groups, i.e. training (80%); validation (10%); and testing (10%). In this study, several CNN architectures are used, such as ResNet50; ResNet101; ResNet152; ResNet50V2; ResNet101V2; ResNet152V; DenseNet121; DenseNet169; DenseNet201; InceptionV3; InceptionResNetV2; VGG16; VGG19; and MobileNetV2. The main objective of this study is to find the CNN architecture that has the best performance in blood cell image-based malaria detection. Comparison of performance of CNN architectures are assessed using accuracy, sensitivity, specificity, F1 score, and *Area Under the Curve* (AUC) values. The MobileNetV2 architecture provides the best performance with the highest average values of training, validation, and testing. The average accuracy value of 97.68%; specificity of 98.61%; sensitivity of 96.75%; F1 Score of 97.70%; and AUC of 0.9965. In addition, the time to build the MobileNetV2 model is about 2.5 hours, the fastest one. This study shows that the number of convolutional layers does not affect malaria detection performance. With 53 convolutional layers, MobileNetV2 has the best performance.

Keywords: artificial intelligent, blood cell image, detection, malaria, mobilenetv2

1. PENDAHULUAN

Menurut data dari *World Health Organisation* (WHO) dalam laporan malaria dunia (*world malaria report*), di tahun 2021 terjadi peningkatan jumlah penderita dibandingkan tahun 2020. Di tahun 2020 terdapat sekitar 245 juta kasus, dan 247 juta kasus di tahun 2021. Diperkirakan sekitar 600 ribu lebih orang meninggal dunia akibat malaria di tahun 2021 maupun 2020 (WHO, 2022).

Salah satu cara penegakan diagnosis malaria adalah menggunakan tes diagnostik cepat. Dianjurkan untuk menggunakan kit tes diagnostik cepat yang memiliki sensitivitas dan spesifisitas minimal 95% (DEPKES, 2008). Penegakan diagnosis malaria juga dapat dilakukan dengan menggunakan analisis citra sediaan darah yang diperoleh dengan menggunakan mikroskop. Diagnosis yang kedua ini merupakan baku emas untuk mendeteksi malaria (Kusuma dkk., 2014).

Pemeriksaan sediaan darah dengan menggunakan mikroskop dilakukan dengan menghitung kepadatan parasit. Analisis yang dilakukan berdasarkan jumlah parasit yang ditemukan dalam satu Lapangan Pandang Besar (LPB). Tabel 1 memperlihatkan analisis jumlah parasit untuk penegakan diagnosis malaria.

Tabel 1. Analisis Jumlah Parasit

Jumlah Parasit	Nilai	LBP
0	Negatif (-)	100
1 – 10	Positif 1 (+)	100
11 – 100	Positif 2 (++)	100
1 – 10	Positif 3 (+++)	1
> 10	Positif 4 (++++)	1

Kendala utama dalam program pencegahan dan penanggulangan penyakit malaria, terutama penegakan diagnosis berbasis analisis citra sediaan darah adalah berkaitan dengan sumber daya manusia. Kelemahan terkait sumber daya manusia ini baik dari sisi kuantitas maupun kualitas tenaga ahli yang memiliki kualifikasi di bidang entomologi dan diagnosis (WHO, 2023). Untuk mengatasi masalah tersebut, dikembangkan teknologi deteksi malaria berbasis kecerdasan buatan (*Artificial Intelligent/AI*). Beberapa kelebihan penggunaan teknologi deteksi berbasis AI ini adalah lebih cepat dan efisien (Nakasi dkk., 2020), (Maturana dkk., 2022). Selain itu, diagnosis malaria berbasis AI dapat diterima secara klinis, terutama di daerah dengan sumber daya, baik ahli maupun peralatan yang terbatas (Liu dkk., 2023).

Secara umum, terdapat dua metode deteksi malaria berbasis AI, yaitu menggunakan pembelajaran mesin (*machine learning*) dan pembelajaran mendalam (*deep learning*). Pembelajaran mesin berbasis pengklasifikasi *Random Forest* (RF) untuk deteksi malaria menghasilkan akurasi, presisi, sensitivitas, dan skor F1 sebesar 96,1%; 97,8%; 94,4%; dan 96,1% (Telang & Sonawane, 2020).

Beberapa tahun terakhir, penggunaan pembelajaran mendalam marak digunakan dalam deteksi malaria berbasis AI. Hal ini dikarenakan beberapa keunggulan yang dimiliki metode pembelajaran mendalam, yaitu (Poostchi dkk., 2018):

- Pengguna tidak perlu menentukan dan mengekstraksi fitur-fitur yang ada pada suatu data,
- Tidak memerlukan adanya prapemrosesan, misalnya segmentasi maupun penentuan *Region of Interest* (RoI),
- Tidak terpengaruh oleh variasi pencahayaan maupun proses *staining*.

Kinerja deteksi malaria berbasis pembelajaran mendalam dengan menggunakan arsitektur Convolutional Neural Networks (CNN) lebih baik dibandingkan dengan pembelajaran mesin (Kumar, Chandiramani, & Kashyap, 2021). Klasifikasi berbasis Support Vector Machine (SVM) memberikan nilai akurasi 85,6% dan Area Under Curve (AUC) 0,932. Sementara, klasifikasi dengan arsitektur CNN DenseNet memberikan nilai akurasi 96,6% dan AUC 0,991 (Narayanan, Ali, & Hardie, 2019). Studi lain yang menggunakan kombinasi CNN untuk deteksi malaria memberikan hasil akurasi sebesar 96,5% (Huda, Dewi, & Mahiruna, 2023). Dengan menggunakan Deep CNN, akurasi deteksi yang diperoleh mencapai 96,7% (Kumar dkk. 2023). Model CNN terkustomisasi yang diberi nama MozzieNet menghasilkan deteksi malaria dengan akurasi 96,73%, skor F1 96,77%, dan AUC 99,35% (Asif dkk., 2024).

Deteksi malaria dengan menggunakan arsitektur *FineTuned* CNN berkinerja lebih baik dibandingkan *Basic* CNN, CGG-19, dan *Frozen* CNN. *FineTuned* CNN memberikan kinerja tertinggi dengan akurasi 0,96; sensitivitas 0,93; spesifisitas 0,98; presisi 0,98; dan skor F1 0,96 (Shekar, Revathy, & Goud, 2020).

Arsitektur *Shallow* ConvNet-18 yang merupakan hasil pengembangan dari CNN memberikan klasifikasi dengan akurasi 97,8%, sensitivitas 97,9%, spesifisitas 97,8%, nilai prediksi positif 97,8%, dan skor F1 97,84% (Elangovan & Nath, 2021). Arsitektur CNN *like sequential* memberikan nilai akurasi pelatihan, validasi, dan pengujian sebesar 98%, 96%, dan 96% (Sinha dkk., 2021). Studi lain yang juga menggunakan CNN terkustomisasi yang disertai dengan pemfilteran bilateral memberikan kinerja akurasi 96,82%, spesifisitas 97,78%, sensitivitas 96,33% dan skor F1 96,82% (Maqsood dkk., 2021). Arsitektur *Data Augmentation Convolutional Neural Network* (DACNN) menghasilkan kinerja akurasi klasifikasi sebesar 94,79% (Oyewola dkk., 2022). Arsitektur berbasis CNN dengan nama Falcon, memberikan akurasi deteksi malaria sebesar 95,2 % (Banerjee dkk., 2022). Sementara, dengan menggunakan arsitektur CNN terkustomisasi diperoleh nilai akurasi 95,90%; presisi 95,6%; dan skor F1 95,57% (Santoshi dkk., 2023).

Arsitektur VGG-19 memberikan hasil akurasi deteksi sebesar 96% (Kuzhaloli dkk., 2023). Deteksi malaria dengan menggunakan arsitektur ResNet dan MobileNet memberikan akurasi sebesar 97,2% dan 94,49% (Yebasse, Cheoi, & Ko, 2023). Sementara, deteksi dengan menggunakan arsitektur Grad-CAM dan Grad-CAM++ memberikan sensitivitas lebih dari 95% (Mridha dkk, 2023). Studi lain yang membandingkan kinerja arsitektur Inception-ResNet, VGG-16, Inception, dan VGG-19 memberikan akurasi sebesar 95%, 92%, 93%, dan 91% (Khan dkk., 2023). Studi lain yang memanfaatkan arsitektur InceptionV3 menghasilkan akurasi sebesar 91,04% (Verma dkk., 2024).

Tabel 2. Pernbandingan metode dan kinerja deteksi malaria		
Penulis (Tahun)	Metode	Metrik
Narayanan, Ali, & Hardie (2019)	CNN DenseNet	akurasi 96,6%, AUC 0,991
Shekar, Revathy, & Goud (2020)	FineTuned CNN	akurasi 96,5%
Vijayalakshmi (2020)	VGG-19 + SVM	akurasi 96,7%
Elangovan & Nath (2021)	Shallow ConvNet-18	akurasi 96,73%, skor F1 96,77%, AUC 99,35%
Sinha dkk. (2021)	CNN like sequential	akurasi 0,96, sensitivitas 0,93, spesifisitas 0,98, skor F1 0,96
Maqsood dkk. (2021)	CNN terkustomisasi + pemfilteran bilateral	akurasi 97,8%, sensitivitas 97,9%, spesifisitas 97,8%, skor F1 97,84%
Oyewola dkk. (2022)	DACNN	akurasi 96,67%
Banerjee dkk. (2022)	CNN	akurasi 96,82%, spesifisitas 97,78%, sensitivitas 96,33%, skor F1 96,82%
Huda, Dewi, & Mahiruna (2023)	kombinasi CNN	akurasi 94,79%
Kumar dkk. (2023)	Deep CNN	akurasi 95,2%
Santoshi dkk. (2023)	CNN terkustomisasi	akurasi 95,90%, skor F1 95,57%
Kuzhaloli dkk. (2023)	VGG-19	akurasi 96%
Yebasse, Cheoi, & Ko (2023)	ResNet	akurasi 97,2%
Mridha dkk. (2023)	Grad-CAM++	sensitivitas 95%
Khan dkk. (2023)	Inception-ResNet	akurasi 95%
Dev dkk. (2023)	CNN-GRU-GRU	akurasi 91,04%
Asif dkk. (2024)	MozzieNet	akurasi 93,13%, sensitivitas 93,44%, spesifisitas 92,92%, skor F1 91,66%
Verma dkk. (2024)	InceptionV3	akurasi 94,32%, skor F1 93,78%
Murmu & Kumar (2024)	DLRNet	akurasi 96,01%

Salah satu teknik yang dapat digunakan untuk meningkatkan kinerja deteksi malaria berbasis citra apusan darah adalah mengombinasikan metode pembelajaran mendalam dengan pembelajaran mesin. Kombinasi arsitektur VGG-19 dengan SVM,

menghasilkan akurasi 93,13%; sensitivitas 93,44%; spesifisitas 92,92%; presisi 89,95%; dan skor F1 91,66% (Vijayalakshmi, 2020). Dengan melakukan kombinasi antara *Residual CNN* dengan SVM, diperoleh kinerja akurasi dan sensitivitas yang tinggi, yaitu 99,90% dan 99,98%, namun nilai spesifisitas yang diperoleh hanya 87,50% (Diker, 2022). Metode kombinasi pembelajaran mendalam dengan *Random Forest* (RF), DLRNet memberikan akurasi deteksi malaria sebesar 94,32% dan skor F1 93,78% (Murmu & Kumar, 2024). Model hibrida CNN-GRU-GRU memberikan akurasi deteksi sebesar 96,01% (Dev dkk., 2023).

Tabel 2 memperlihatkan hasil studi-studi deteksi malaria berbasis citra apusan darah menggunakan pendekatan AI berbasis CNN. Dapat dilihat bahwa studi-studi tersebut memiliki kinerja yang tinggi, namun demikian kinerjanya masih dapat ditingkatkan. Salah satu cara yang dapat digunakan untuk meningkatkan kinerja deteksi malaria adalah menggunakan manipulasi data (*data augmentation*) pada saat pembuatan model. Oleh karena itu, pada studi ini digunakan beberapa parameter manipulasi data dengan nilai tertentu untuk meningkatkan kinerja deteksi malaria. Selain itu, pada studi-studi sebelumnya, kinerja deteksi malaria diukur hanya dengan menggunakan satu atau dua atau tiga metrik sebagai berikut: akurasi, sensitivitas, spesifisitas, skor F1, dan *Area Under Curve* (AUC). Sementara, pada studi ini Kinerja deteksi malaria dievaluasi dengan menggunakan semua metrik tersebut, yaitu akurasi, sensitivitas, spesifisitas, skor F1, dan AUC. Beberapa studi-studi sebelumnya hanya menampilkan kinerja terbaik dari pelatihan atau pengujian. Sementara, pada studi ini ditampilkan nilai kinerja pelatihan, validasi, serta pelatihan. Hal ini bermanfaat untuk mengevaluasi model yang dibangun dalam kondisi *underfitting* atau *overfitting*.

2. METODE PENELITIAN

2.1. Set Data

Pada studi ini, digunakan set data citra apusan darah malaria dari *National Library of Medicine* (NLM). Set data ini diperoleh dari 150 preparat apusan darah yang terinfeksi plasmodium falciparum dan 50 preparat apusan darah tidak terinfeksi. Apusan darah ini dikumpulkan oleh Chittagong *Medical College Hospital*, Bangladesh (Rajaraman dkk., 2018). Terdapat 27.558 citra sel darah yang diperoleh dari 150 preparat apusan darah tersebut. Jumlah citra sel yang terinfeksi dan tidak terinfeksi masing-masing sebesar 13.779 dan 13.779. Citra-citra sel darah tersebut dibagi menjadi tiga kelompok yang digunakan untuk pelatihan, validasi, dan pengujian dengan persentase sebesar 80%, 10%, dan 10%. Rincian jumlah citra sel darah terinfeksi dan tidak terinfeksi untuk proses pelatihan, validasi, dan pengujian dapat dilihat pada Tabel 3.


Tabel 3. Rincian Jumlah Citra Apusan Darah

	Tidak Terinfeksi	Terinfeksi
Pelatihan	11.203	11.203
Validasi	1.377	1.377
Pengujian	1.379	1.379
Subtotal	13.779	13.779
Total	27.558	


Contoh citra sel darah tidak terinfeksi parasit malaria dapat dilihat pada Gambar 1. Sementara, contoh citra sel darah terinfeksi parasit malaria diperlihatkan pada Gambar 2.

2.2. Arsitektur CNN

Pada studi ini, juga dilakukan perbandingan kinerja 14 arsitektur CNN yang telah umum digunakan dalam deteksi berbasis AI. Arsitektur-arsitektur CNN ini memiliki jumlah lapisan *convolutional* yang berbeda-beda. Oleh karena itu, salah satu tujuan dalam studi ini adalah mengeksplorasi pengaruh jumlah lapisan *convolutional* terhadap kinerja deteksi malaria berbasis citra sel darah.



Gambar 1. Citra sel darah tidak terinfeksi



Gambar 2. Citra sel darah terinfeksi

Terdapat enam arsitektur CNN berbasis *Residual Neural Network* atau disebut juga dengan *Residual Network* (ResNet) yang digunakan dalam studi ini, yang terdiri dari tiga ResNet versi 1 dan tiga ResNet versi 2. Keenam versi ResNet tersebut adalah ResNet50, ResNet101, ResNet152, ResNet50V2,

ResNet101V2, dan ResNet152V2. Arsitektur CNN berikutnya yang dicoba dalam studi ini adalah berbasis *Dense Convolutional Network* (DenseNet). Terdapat tiga jenis DenseNet yang digunakan, yaitu DenseNet121, DenseNet169, dan DenseNet201. Arsitektur CNN selanjutnya berbasis Inception, yaitu InceptionV3 dan InceptionResNetV2. Selain itu, arsitektur CNN yang dikembangkan oleh *Visual Geometry Group* (VGG), yaitu VGG16 dan VGG19. Arsitektur terakhir yang digunakan dalam studi ini adalah MobileNetV2 dengan keunggulan memerlukan sumber daya komputasi yang relatif lebih rendah dibandingkan dengan arsitektur CNN yang lain. Tabel 4 memperlihatkan arsitektur-arsitektur CNN yang digunakan dalam studi ini beserta dengan jumlah lapisan *convolutional*.

Tabel 4. Jumlah Lapisan *Convolutional*

Arsitektur	Jumlah Lapisan
ResNet50	50
ResNet101	101
ResNet152	152
ResNet50V2	50
ResNet101V2	101
ResNet152V2	152
DenseNet121	121
DenseNet169	169
DenseNet201	201
InceptionV3	48
InceptionResNetV2	164
VGG16	13
VGG19	19
MobileNetV2	53

Data yang digunakan berjumlah 27.558 citra. Meskipun jumlah citra yang digunakan relatif banyak, namun pada studi ini tetap dilakukan proses manipulasi (*augmentation*) data. Hal ini untuk memastikan bahwa model deteksi malaria yang dibuat dengan menggunakan pembelajaran mendalam berbasis CNN memiliki kinerja yang lebih baik. Parameter-parameter manipulasi data beserta nilai yang digunakan dapat dilihat pada Tabel 5.

Tabel 5. Parameter Manipulasi Data

Manipulasi Data	Nilai
Dimensi target citra	224 × 224 piksel
Ukuran kelompok	32
Rentang perbesaran	0,2
Rentang pergeseran	0,2
Pembalikan vertical	Ya
Rentang pergeseran lebar	0,2
Rentang pergeseran tinggi	0,2
Mode pengisian	<i>nearest</i>

2.3. Metrik Kinerja

Metrik yang digunakan untuk mengukur kinerja deteksi malaria berbasis citra sel darah menggunakan pembelajaran mendalam didasarkan pada nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Ilustrasi nilai-nilai ini dapat dilihat pada *confusion matrix* di Gambar 3.

		Nilai Sebenarnya	
		Positive	Negative
Nilai Prediksi	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

Gambar 3. Citra sel darah terinfeksi

Akurasi dihitung dengan membagi nilai prediksi yang benar (TP dan TN) dengan semua data seperti pada persamaan (1). Pada persamaan (2), sensitivitas atau disebut juga dengan *True Positive Rate* (TPR) dihitung dengan membagi nilai TP dengan semua nilai positif sebenarnya (TP dan FN). Pada persamaan (3), nilai spesifisitas dihitung dengan membagi nilai TN dengan semua nilai negatif sebenarnya (TN dan FP). Selain ketiga metrik tersebut, metrik lain yang digunakan dalam studi ini adalah skor F1. Metrik ini fokus tidak hanya pada nilai FP tetapi juga FN. Skor F1 dihitung dengan menggunakan persamaan (4).

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Sensitivitas} = \text{TPR} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Spesifisitas} = \frac{TN}{TN+FP} \quad (3)$$

$$\text{Skor F1} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (4)$$

$$\text{FPR} = 1 - \text{Spesifisitas} = \frac{FP}{TN+FP} \quad (5)$$

Metrik terakhir yang digunakan dalam studi ini adalah AUC-ROC. Metrik AUC sering digunakan untuk menganalisis kinerja deteksi ketika jumlah data positif dan negatifnya seimbang. Selain itu, AUC-ROC berfungsi dengan baik dalam mengarakterisasi kinerja model deteksi atau klasifikasi (Erickson & Kitamura, 2021). AUC dihitung dengan menggunakan nilai TPR pada persamaan (2) dan FPR pada persamaan (5). Nilai FPR dapat dipengaruhi oleh nilai spesifisitas. Semakin tinggi nilai spesifisitas, maka nilai FPR akan semakin kecil dan sebaliknya.

Kurva ROC merupakan grafik antara FPR dengan TPR pada nilai *cut-off* tertentu. Pada saat *cut-off* probabilitas dikurangi akan meningkatkan sensitivitas / TPR dan menurunkan spesifisitas, sehingga meningkatkan FPR (1 - spesifisitas). Ketika nilai *cut-off* probabilitas dinaikkan akan meningkatkan spesifisitas dan menurunkan sensitivitas.


Tabel 6. Arti Nilai AUC

Nilai AUC	Kualitas
0,9 – 1,0	Excellent
0,8 – 0,9	Sangat Baik
0,7 – 0,8	Baik
0,6 – 0,7	Cukup
0,5 – 0,6	Kurang

Arti kualitas rentang nilai AUC diperlihatkan dalam Tabel 6 (Trifonova, Lokhov, & Archakov, 2013). Rentang nilai AUC yang diberikan ini sesuai

dengan penjelasan dan ilustrasi pada Gambar 4, 5, dan 6, yaitu 0,5 – 1,0. Rentang nilai ini dibagi menjadi lima kualitas, yaitu *Excellent*, sangat baik, baik, cukup, dan kurang.

Secara umum, diagram blok sistem deteksi malaria menggunakan citra sel darah berbasis CNN yang diusulkan dalam studi ini dapat dilihat pada Gambar 4. Terdapat dua proses utama, yaitu klasifikasi berbasis CNN dan pengukuran kinerja klasifikasi. Kinerja ini diukur dengan metrik berupa akurasi, sensitivitas, spesifisitas, skor F1, dan AUC yang digunakan untuk memilih model klasifikasi terbaik.



Gambar 4. Diagram blok sistem deteksi malaria menggunakan citra sel darah berbasis CNN

3. HASIL DAN PEMBAHASAN


Kinerja deteksi malaria menggunakan citra sel darah berbasis pembelajaran mendalam dengan arsitektur CNN diukur dengan menggunakan nilai akurasi, sensitivitas, spesifisitas, skor F1, dan AUC. Untuk masing-masing metrik kinerja tersebut, terdapat empat nilai yang dihasilkan, yaitu pelatihan; validasi; pengujian; dan rata-rata.

Tabel 7. Akurasi

Arsitektur	Pelatihan	Validasi	Pengujian	Rata-rata
ResNet50	96,11	96,73	96,74	96,53
ResNet101	95,77	96,77	96,88	96,47
ResNet152	95,89	96,84	97,10	96,61
ResNet50V2	96,07	97,17	97,17	96,80
ResNet101V2	95,64	96,59	96,92	96,38
ResNet152V2	95,40	96,59	96,77	96,25
DenseNet121	97,03	97,35	97,53	97,30
DenseNet169	97,03	97,57	97,93	97,51
DenseNet201	97,39	97,17	98,01	97,52
InceptionV3	96,01	96,73	97,14	96,63
InceptionResNetV2	97,46	97,24	97,86	97,52
VGG16	94,93	95,90	96,59	95,81
VGG19	94,92	96,08	96,66	95,89
MobileNetV2	97,47	97,64	97,93	97,68

Nilai akurasi untuk masing-masing arsitektur CNN yang digunakan dalam studi ini dapat dilihat

pada Tabel 7. Nilai akurasi paling rendah diperoleh pada deteksi menggunakan arsitektur VGG16, dengan nilai rata-rata hanya 95,81%. Sementara, nilai tertinggi dicapai dengan menggunakan arsitektur MobileNetV2 dengan nilai rata-rata mencapai 97,68%. Gambar 5 memperlihatkan grafik pembuatan model deteksi malaria berbasis MobileNetV2. Dari grafik tersebut terlihat bahwa nilai akurasi pelatihan dan validasi berimpitan setelah *epoch* ke-10. Sehingga model deteksi malaria yang dibangun dengan menggunakan arsitektur MobileNetV2 ini dalam kondisi *best fitting*.



Gambar 5. Grafik pembuatan model deteksi malaria berbasis MobileNetV2

Parameter lain yang digunakan dalam studi ini adalah sensitivitas dan spesifisitas. Kedua parameter kinerja ini sangat umum digunakan dalam deteksi atau diagnosis di bidang medis. Tabel 8 memperlihatkan nilai sensitivitas dari pelatihan, validasi, pengujian, beserta rata-ratanya. Arsitektur VGG19 memberikan nilai rata-rata terendah, yaitu sekitar 97,42%. Sementara, Arsitektur MobileNetV2 memberikan nilai rata-rata tertinggi, yaitu mencapai 98,61%.

Tabel 8. Sensitivitas

Arsitektur	Pela- tihan	Vali- dasi	Pengu- jian	Rata- rata
ResNet50	97,11	97,53	98,98	97,87
ResNet101	97,09	97,97	98,62	97,89
ResNet152	97,08	97,97	98,55	97,87
ResNet50V2	97,02	97,68	98,77	97,82
ResNet101V2	96,92	97,97	98,77	97,88
ResNet152V2	96,92	97,89	98,33	97,71
DenseNet121	97,78	97,82	98,69	98,10
DenseNet169	97,65	98,11	98,69	98,15
DenseNet201	98,04	97,82	98,62	98,16
InceptionV3	97,02	97,82	98,62	97,82
InceptionResNetV2	98,31	97,60	98,55	98,16
VGG16	96,53	97,60	98,62	97,59
VGG19	96,69	97,10	98,48	97,42
MobileNetV2	98,24	98,55	99,06	98,61

Nilai spesifisitas dari pelatihan, validasi, pengujian, dan rata-ratanya diperlihatkan pada Tabel 9. Nilai rata-rata spesifisitas terendah diperoleh dengan menggunakan arsitektur VGG16 yaitu hanya sebesar 94,03%. Sementara, Arsitektur MobileNetV2

memberikan nilai rata-rata sensitifitas sebesar 96,75%. Nilai rata-rata tertinggi diperoleh dengan menggunakan arsitektur DenseNet201 dan InceptionResNetV2 sebesar 96,88%.

Tabel 9. Spesifisitas

Arsitektur	Pela- tihan	Vali- dasi	Pengu- jian	Rata- rata
ResNet50	95,11	95,93	94,49	95,18
ResNet101	94,46	95,57	95,14	95,06
ResNet152	94,71	95,72	95,65	95,36
ResNet50V2	95,12	96,66	95,58	95,79
ResNet101V2	94,36	95,21	95,07	94,88
ResNet152V2	93,89	95,28	95,21	94,79
DenseNet121	96,28	96,88	96,37	96,51
DenseNet169	96,42	97,02	97,17	96,87
DenseNet201	96,74	96,51	97,39	96,88
InceptionV3	95,00	95,64	95,65	95,43
InceptionResNetV2	96,60	96,88	97,17	96,88
VGG16	93,33	94,19	94,56	94,03
VGG19	93,14	95,06	94,85	94,35
MobileNetV2	96,71	96,73	96,81	96,75

Parameter kinerja keempat yang digunakan dalam studi ini adalah skor F1. Parameter kinerja ini juga sering digunakan dalam deteksi atau diagnosis medis berbasis pembelajaran mendalam. Pada studi ini, rata-rata skor F1 terendah dicapai dengan menggunakan arsitektur VGG16 yang mencapai 95,88%. Sedangkan arsitektur MobileNetV2 memberikan nilai rata-rata skor F1 tertinggi, yaitu sebesar 97,70%. Detail nilai pelatihan, validasi, pengujian, dan rata-rata skor F1 dari beberapa arsitektur CNN yang digunakan dalam studi ini ditampilkan pada Tabel 10.

Parameter kinerja terakhir yang digunakan dalam studi ini adalah AUC. Parameter kinerja ini juga sering digunakan untuk melakukan asesmen kinerja deteksi atau diagnosis medis berbasis pembelajaran mendalam. Pada studi ini, skor F1 terendah dihasilkan oleh arsitektur VGG19 dengan nilai sebesar 98,79%. Nilai tertinggi dicapai oleh arsitektur DenseNet201 dengan nilai sebesar 99,67%. Sementara, nilai AUC dari arsitektur MobileNetV2 mencapai 99,65%. Rincian nilai AUC dari pelatihan, validasi, pengujian, dan rata-ratanya diperlihatkan pada Tabel 11.

Tabel 10. Skor F1

Arsitektur	Pela- tihan	Vali- dasi	Pengu- jian	Rata- rata
ResNet50	96,15	96,76	96,81	96,57
ResNet101	95,83	96,81	96,94	96,52
ResNet152	95,94	96,88	97,14	96,65
ResNet50V2	96,11	97,18	97,22	96,84
ResNet101V2	95,69	96,63	96,97	96,43
ResNet152V2	95,47	96,63	96,82	96,31
DenseNet121	97,05	97,36	97,56	97,33
DenseNet169	97,05	97,58	97,95	97,53
DenseNet201	97,41	97,19	98,02	97,54
InceptionV3	96,05	96,77	97,18	96,67
InceptionResNetV2	97,48	97,25	97,88	97,53
VGG16	95,01	95,97	96,66	95,88
VGG19	95,00	96,12	96,72	95,95
MobileNetV2	97,49	97,66	97,96	97,70

Tabel 11. AUC

Arsitektur	Pela- tihan	Vali- dasi	Pengu- jian	Rata- rata
ResNet50	0,9910	0,9955	0,9948	0,9938
ResNet101	0,9891	0,9948	0,9943	0,9927
ResNet152	0,9903	0,9944	0,9953	0,9933
ResNet50V2	0,9904	0,9954	0,9955	0,9938
ResNet101V2	0,9891	0,9950	0,9947	0,9929
ResNet152V2	0,9871	0,9939	0,9933	0,9914
DenseNet121	0,9945	0,9959	0,9964	0,9956
DenseNet169	0,9947	0,9968	0,9963	0,9959
DenseNet201	0,9957	0,9976	0,9967	0,9967
InceptionV3	0,9914	0,9949	0,9953	0,9939
InceptionResNetV2	0,9952	0,9963	0,9970	0,9962
VGG16	0,9829	0,9911	0,9915	0,9885
VGG19	0,9817	0,9905	0,9914	0,9879
MobileNetV2	0,9951	0,9967	0,9977	0,9965

Secara umum, arsitektur MobileNetV2 memberikan kinerja yang paling baik dibandingkan dengan arsitektur-arsitektur untuk mendeteksi malaria dengan menggunakan citra sel darah. Arsitektur MobileNetV2 memiliki nilai akurasi, sensitivitas, spesifisitas, dan skor F1 tertinggi. Sedangkan untuk nilai AUC, arsitektur MobileNetV2 hanya selisih 0,0002 dari DenseNet201. Hasil ini sejalan dengan studi terdahulu yang menyatakan bahwa MobileNetV2 memiliki akurasi deteksi malaria tertinggi (Kakkar dkk., 2023).

Tabel 12. Perbandingan Kinerja Deteksi Malaria berbasis Citra Sel Darah

Penulis	Aku. (%)	Sen. (%)	Spe. (%)	Skor F1 (%)	AUC (%)
Narayanan, dkk.	96,6	-	-	-	99,1
Shekar, dkk.	96,5	-	-	-	-
Vijayalakshmi	96,7	-	-	-	-
Elangovan & Nath	96,73	-	-	96,77	99,35
Sinha dkk.	0,96	0,93	0,98	0,96	-
Maqsood dkk.	97,8	97,9	97,8	97,84	-
Oyewola dkk.	96,67	-	-	-	-
Banerjee dkk.	96,82	97,78	96,33	96,82	-
Kuzhaloli dkk.	96	-	-	-	-
Yebasse, dkk.	97,2	-	-	-	-
Verma dkk.	94,32	-	-	93,78	-
Setiawan, A. W.	97,68	98,61	96,75	97,70	99,65

Tabel 13. Nilai Rata-rata Metrik Kinerja Deteksi Malaria Berbasis CNN Dengan Menggunakan Manipulasi Data

Arsitektur	Aku. (%)	Sen. (%)	Spe. (%)	Skor F1 (%)	AUC (%)
ResNet50	96,91	98,24	95,57	96,94	99,36
ResNet101	96,52	97,13	95,91	96,54	99,25
ResNet152	96,76	97,81	95,71	96,79	99,27
ResNet50V2	96,97	98,15	95,78	97,00	99,29
ResNet101V2	97,02	98,13	95,91	97,06	99,29
ResNet152V2	97,13	97,83	96,42	97,15	99,44
DenseNet121	97,61	98,57	96,65	97,63	99,65
DenseNet169	97,56	98,18	96,94	97,58	99,60
DenseNet201	97,42	98,19	96,65	97,44	99,59
InceptionV3	96,31	98,60	94,01	96,40	99,18
Inception-ResNetV2	97,73	98,59	96,86	97,75	99,70
VGG16	99,62	97,91	95,33	96,66	99,24
VGG19	96,79	97,77	95,82	96,83	99,39
MobileNetV2	98,10	98,89	97,30	98,12	99,48

Deteksi malaria menggunakan citra sel darah berbasis arsitektur MobileNetV2 yang dikembangkan dalam studi ini memiliki kinerja yang lebih baik

dibandingkan dengan penelitian-penelitian sebelumnya. Tabel 12 memperlihatkan perbandingan metrik kinerja deteksi yang diukur dengan menggunakan parameter Akurasi (Aku.), Sensitivitas (Sen.), Spesifisitas (Spe.), skor F1, dan AUC.

Nilai rata-rata akurasi, sensitivitas, spesifisitas, skor F1, dan AUC untuk deteksi malaria berbasis CNN tanpa adanya manipulasi data ditunjukkan pada Tabel 13. Secara umum, nilai rata-rata kelima metrik ini lebih rendah dibandingkan dengan konfigurasi dengan menggunakan manipulasi data.

Pada studi ini, evaluasi kinerja deteksi malaria juga dilakukan perbandingan parameter beban komputasi yang diperlukan oleh setiap arsitektur Pembelajaran mendalam. Kinerja ini ditentukan dengan menghitung waktu total pembuatan model arsitektur-arsitektur yang digunakan dalam studi ini. Rincian waktu pembuatan model ini dapat dilihat pada Tabel 14. Terlihat bahwa waktu pembuatan model tercepat didapatkan dengan menggunakan arsitektur MobileNetV2 yang hanya memerlukan sekitar 2,5 jam. Meskipun VGG16 dan VGG19 memiliki kinerja akurasi, sensitivitas, spesifisitas, skor F1, dan AUC paling rendah; namun memerlukan waktu pembuatan model yang relatif lama. Bahkan, arsitektur VGG19 memerlukan waktu pembuatan model terlama, yaitu mencapai 32,5 jam.

Tabel 14. Waktu Pembuatan Model

Arsitektur	Waktu per epoch (dtk)	# epoch	Total Waktu (Jam)
ResNet50	1.272	17	6,0
ResNet101	2.245	19	11,8
ResNet152	3.285	22	20,1
ResNet50V2	1.119	19	5,9
ResNet101V2	2.118	18	10,6
ResNet152V2	3.190	26	23,0
DenseNet121	1.376	34	13,0
DenseNet169	1.636	14	6,4
DenseNet201	2.122	31	18,3
InceptionV3	672	27	5,0
InceptionResNetV2	1.620	28	12,6
VGG16	3.288	17	15,5
VGG19	4.040	29	32,5
MobileNetV2	448	20	2,5

Kinerja deteksi malaria berbasis citra sel darah menggunakan pembelajaran mendalam tidak dipengaruhi oleh jumlah lapisan *convolutional*. Meskipun arsitektur MobileNetV2 memiliki jumlah lapisan 53, namun menunjukkan kinerja yang paling baik. Selain itu, waktu pembuatan model dengan menggunakan MobileNetV2 juga paling cepat. Hal ini sesuai dengan arsitektur MobileNetV2 yang menggunakan konvolusi mendalam yang ringan untuk memfilter fitur di lapisan ekspansi tengah. Selain itu, arsitektur MobileNetV2 juga menghilangkan ketidaklinearan di lapisan sempit (Sandler dkk., 2018). Dengan demikian, arsitektur MobileNetV2 ini tidak terlalu banyak mempelajari derau, sehingga menghasilkan kinerja yang lebih baik. Dengan arsitektur tersebut, MobileNetV2 menjadi sangat efisien dalam membangun model

(Gjesteby dkk., 2023). Hasil yang diperoleh dalam studi ini bersesuaian dengan studi sebelumnya yang menyatakan bahwa arsitektur MobileNetV2 lebih unggul dibandingkan arsitektur CNN yang lain, terutama pada bidang medis (Akay dkk., 2021).

4. KESIMPULAN

Pada studi ini dilakukan deteksi malaria berbasis citra sel darah berbasis arsitektur pembelajaran mendalam, yaitu: ResNet50, ResNet101, ResNet152, ResNet50V2, ResNet101V2, ResNet152V2, DenseNet121, DenseNet169, DenseNet201, InceptionV3, VGG16, VGG19, InceptionResNetV2, dan MobileNetV2. Diperoleh hasil arsitektur MobileNetV2 memiliki kinerja lebih baik dibandingkan dengan arsitektur-arsitektur yang lain. Kinerja ini terlihat dari nilai rata-rata akurasi 97,68%; spesifisitas 98,61%; sensitivitas 96,75%; Skor F1 97,70%; dan AUC sebesar 0,9965. Selain itu, waktu pembuatan model tercepat diperoleh dengan menggunakan arsitektur MobileNetV2, yaitu sekitar 2,5 jam. Pada studi ini, kinerja deteksi malaria berbasis citra sel darah menggunakan pembelajaran mendalam tidak dipengaruhi oleh jumlah lapisan *convolutional*. Salah satu potensi pengembangan yang dapat dilakukan adalah pendeteksian malaria berbasis citra sel darah dapat dilakukan dengan menggunakan model MobileNetV2 yang diaplikasikan di sebuah *smartphone* yang terhubung dengan mikroskop.

Salah satu batasan pada studi ini adalah citra sel darah yang digunakan bertipe RGB. Sehingga, penelitian lanjutan yang akan dilakukan adalah melihat pengaruh ruang warna yang lain pada deteksi malaria dengan menggunakan pembelajaran mendalam. Selain itu, meskipun studi ini telah menghasilkan deteksi malaria yang lebih baik, namun masih terdapat peluang perbaikan yang dapat dilakukan untuk dapat meningkatkan akurasi, spesifisitas, skor F1, dan AUC menjadi 100%. Salah satu cara yang dapat dilakukan adalah dengan melihat pengaruh parameter-parameter manipulasi data serta *fine tuning* perlu dieksplor lebih lanjut.

DAFTAR PUSTAKA

- AKAY, M., DU, Y., SERSHEN, C.L., WU, M., CHEN, T.Y., ASSASSI, S., MOHAN, C. dan AKAY, Y.M., 2021. Deep learning classification of systemic sclerosis skin using the MobileNetV2 model. *IEEE Open Journal of Engineering in Medicine and Biology*, 2, pp. 104-110.
- ASIF, S., KHAN, S.U.R., ZHENG, X. dan ZHAO, M., 2024. MozzieNet: A deep learning approach to efficiently detect malaria parasites in blood smear images. *International Journal of Imaging Systems and Technology*, 34(1), p.e22953.
- BANERJEE, T., JAIN, A., SETHURAMAN, S.C., SATAPATHY, S.C., KARTHIKEYAN, S. dan JUBILSON, A., 2022. Deep Convolutional Neural Network (Falcon) and transfer learning-based approach to detect malarial parasite. *Multimedia Tools and Applications*, 81(10), pp.13237-13251.
- DEPKES (Departemen Kesehatan Republik Indonesia), 2008. Pedoman penatalaksanaan kasus malaria di Indonesia. Jakarta: Ditjen Pengendalian Penyakit dan Penyehatan Lingkungan.
- DEV, A., FOU DA, M.M., KERBY, L. dan FADLULLAH, Z.M., 2023. On improving malaria parasite detection from microscopic images: A comparative analytics of hybrid deep learning models. 2023 11th International Conference on Information and Communication Technology (ICICT). pp. 417-422. IEEE.
- DIKER, A., 2022. An efficient model of residual based convolutional neural network with Bayesian optimization for the classification of malarial cell images. *Computers in Biology and Medicine*, 148, p.105635.
- ELANGO VAN, P. dan NATH, M.K., 2021. A novel shallow convnet-18 for malaria parasite detection in thin blood smear images: Cnn based malaria parasite detection. *SN computer science*, 2(5), p.380.
- ERICKSON, B.J. dan KITAMURA, F., 2021. Magician's corner: 9. Performance metrics for machine learning models. *Radiology: Artificial Intelligence*, 3(3), p.e200126.
- GJESTEBY, L.A., HABER, E., HAKOZAKI, S., XU, A., DELOSA, N., ROOP, B., WERBLIN, J., TELFER, B. dan BRATTAIN, L.J., 2023. Optimizing MobileNet Algorithms for Real-time Vessel Detection on Smartphones. In 2023 IEEE 19th International Conference on Body Sensor Networks (BSN). pp. 1-4. IEEE.
- HUDA, N., DEWI, A.Y. dan MAHIRUNA, A., 2023. Plasmodium falciparum Identification Using Otsu Thresholding Segmentation Method Based on Microscopic Blood Image. *Scientific Journal of Informatics*, 10(4), pp. 479-488.
- KAKKAR, B., GOYAL, M., JOHRI, P. dan KUMAR, Y., 2023. Artificial Intelligence-Based Approaches for Detection and Classification of Different Classes of Malaria Parasites Using Microscopic Images: A Systematic Review. *Archives of Computational Methods in Engineering*, pp. 1-20.
- KHAN, G.Z., SHAH, I.A., HASSAN, M.A., JUNAID, H. dan SARDAR, F., 2023.

- Intelligent Systems for early malaria disease detection in patient cells using transfer learning approaches. In 2023 4th International Conference on Computing, Mathematics and Engineering Technologies (iCoMET). pp. 1-6. IEEE.
- KUMAR, K., CHANDIRAMANI, G. dan KASHYAP, K.L., 2021. Computer-Aided Malaria Detection Based on Computer Vision and Deep Learning Approach. Machine Vision and Augmented Intelligence - Theory and Applications: Select Proceedings of MAI 2021. pp. 541-551. Springer Singapore.
- KUMAR, S., VARDHAN, H., PRIYA, S. dan KUMAR, A., 2023. Malaria detection using deep convolution neural network. arXiv preprint arXiv:2303.03397.
- KUSUMA, W., LESTARI, A.W., HERAWATI, S. dan YASA, I.W.P.S., 2014. Pemeriksaan Mikroskop Dan Tes Diagnostik Cepat Dalam Menegakkan Diagnosis Malaria. E-Jurnal Medika Udayana, 3(2), pp. 170-186.
- KUZHALOLI, S., THENAPPAN, S., PREMAVATHI, T., NIVEDITA, V., MAGESHBABU, M. dan NAVANEETHAN, S., 2023, February. Identification of Malaria Disease Using Machine Learning Models. 2023 Fifth International Conference on Electrical, Computer and Communication Technologies (ICECCT). pp. 1-4. IEEE.
- LIU, R., LIU, T., DAN, T., YANG, S., LI, Y., LUO, B., ZHUANG, Y., FAN, X., ZHANG, X., CAI, H. dan TENG, Y., 2023. AIDMAN: An AI-based object detection system for malaria diagnosis from smartphone thin-blood-smear images. Patterns, 4(9).
- MAQSOOD, A., FARID, M.S., KHAN, M.H. dan GRZEGORZEK, M., 2021. Deep malaria parasite detection in thin blood smear microscopic images. Applied Sciences, 11(5), p.2284.
- MATURANA, C.R., DE OLIVEIRA, A.D., NADAL, S., BILALLI, B., SERRAT, F.Z., SOLEY, M.E., IGUAL, E.S., BOSCH, M., LLUCH, A.V., ABELLÓ, A. dan LÓPEZ-CODINA, D., 2022. Advances and challenges in automated malaria diagnosis using digital microscopy imaging with artificial intelligence tools: A review. Frontiers in microbiology, 13, p.1006659.
- MRIDHA, K., TOLA, F.G., SARKAR, S., AREFIN, N., GHIMIRE, S., ARAN, A. dan PANDEY, A.P., 2023, June. Automating Malaria Diagnosis with XAI: Using Deep-Learning Technologies for More Accurate, Efficient, and Transparent Results. In International Conference on Multi-disciplinary Trends in Artificial Intelligence, pp. 297-308. Cham: Springer Nature Switzerland.
- MURMU, A. dan KUMAR, P., 2024. DLRFNet: deep learning with random forest network for classification and detection of malaria parasite in blood smear. Multimedia Tools and Applications, pp. 1-23.
- NAKASI, R., MWEBAZE, E., ZAWEDDE, A., TUSUBIRA, J., AKERA, B. dan MAIGA, G., 2020. A new approach for microscopic diagnosis of malaria parasites in thick blood smears using pre-trained deep learning models. SN Applied Sciences, 2, pp. 1-7.
- NARAYANAN, B.N., ALI, R. dan HARDIE, R.C., 2019, September. Performance analysis of machine learning and deep learning architectures for malaria detection on cell images. In Applications of Machine Learning, 11139, pp. 240-247. SPIE.
- OYEWOLA, D.O., DADA, E.G., MISRA, S. dan DAMAŠEVIČIUS, R., 2022. A novel data augmentation convolutional neural network for detecting malaria parasite in blood smear images. Applied Artificial Intelligence, 36(1), p.2033473.
- POOSTCHI, M., SILAMUT, K., MAUDE, R.J., JAEGER, S. dan THOMA, G., 2018. Image analysis and machine learning for detecting malaria. Translational Research, 194, pp. 36-55.
- RAJARAMAN, S., ANTANI, S.K., POOSTCHI, M., SILAMUT, K., HOSSAIN, M.A., MAUDE, R.J., JAEGER, S. dan THOMA, G.R., 2018. Pre-trained convolutional neural networks as feature extractors toward improved malaria parasite detection in thin blood smear images. PeerJ, 6, p.e4568.
- SANDLER, M., HOWARD, A., ZHU, M., ZHMOGINOV, A. dan CHEN, L.C., 2018. Mobilenetv2: Inverted residuals and linear bottlenecks. Proceedings of the IEEE conference on computer vision and pattern recognition. pp. 4510-4520.
- SANTOSHI, K., SARANYA, G., REDDY, C.R., REDDY, C.J., GYANANANDU, K. dan TEJ, G.N., 2023, May. Deep Learning based Web App for Malaria Parasite Detection in Granular Blood Samples. In 2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAIC). pp. 291-297. IEEE.
- SHEKAR, G., REVATHY, S. dan GOUD, E.K., 2020, June. Malaria detection using deep learning. In 2020 4th international conference on trends in electronics and

- informatics (ICOEI), 48184, pp. 746-750. IEEE.
- SINHA, S., SRIVASTAVA, U., DHIMAN, V., AKHILAN, P.S. dan MISHRA, S., 2021. Performance assessment of Deep Learning procedures on Malaria dataset. *Journal of Robotics and Control (JRC)*, 2(1), pp. 12-18.
- TELANG, H. dan SONAWANE, K., 2020, October. Effective performance of bins approach for classification of malaria parasite using machine learning. 2020 IEEE 5th International Conference on Computing Communication and Automation (ICCCA), pp. 427-432. IEEE.
- TRIFONOVA, O.P., LOKHOV, P.G. dan ARCHAKOV, A.I., 2013. Metabolic profiling of human blood. *Biochemistry (Moscow) Supplement Series B: Biomedical Chemistry*, 7, pp. 179-186.
- VERMA, A., MANSOORI, S., SRIVASTAVA, A., RATHEE, P. dan SINGH, N.P., 2024. Deep learning driven automated malaria parasite detection in thin blood smears. In *Artificial Intelligence, Blockchain, Computing and Security*, 1, pp. 375-380. CRC Press.
- VIJAYALAKSHMI, A., 2020. Deep learning approach to detect malaria from microscopic images. *Multimedia Tools and Applications*, 79, pp. 15297-15317.
- WHO (World Health Organization), 2022. World malaria report 2022. World Health Organization.
- WHO (World Health Organization), 2023. Report of the first and second meetings of the technical advisory group on malaria elimination and certification, 13–14 September 2022 and 27 January 2023.
- YEBASSE, M., CHEOI, K.J. dan KO, J., 2023. Malaria Disease Cell Classification With Highlighting Small Infected Regions. *IEEE Access*, 11, pp. 15945-15953.