

# Pemodelan Sistem Deteksi Parasit Malaria pada Citra Mikroskopis Sel Darah Menggunakan Metode *Deep Learning*

Nurhaeni<sup>1</sup>  
Septyan Eka Prastya<sup>2\*</sup>  
Ahmad Hidayat<sup>3</sup>  
Fadhiyah Noor Anisa<sup>4</sup>

<sup>1,3</sup>Program Studi Sarjana Sistem Informasi, Universitas Sari Mulia, Indonesia

<sup>2</sup> Program Studi Sarjana Teknologi Informasi, Universitas Sari Mulia, Indonesia

<sup>4</sup> Program Studi Diploma Tiga Kebidanan, Universitas Sari Mulia, Indonesia

<sup>1</sup>nurhaeni@unism.ac.id, <sup>2</sup>septyan.e.prastya@unism.ac.id, <sup>3</sup>ahmadhidayat@unism.ac.id,

<sup>4</sup>fadhiyahnooranisa@unism.ac.id

**\*Penulis Korespondensi:**

Septyan Eka Prastya

septyan.e.prastya@unism.ac.id

## Abstrak

Pemeriksaan mikroskopis adalah teknik pemeriksaan malaria yang paling umum digunakan di fasilitas Kesehatan. Namun, pemeriksaan mikroskopis memerlukan keahlian khusus dan waktu yang cukup lama. Penelitian ini bertujuan mengembangkan model sistem deteksi parasit malaria dalam citra sel darah menggunakan teknologi deep learning untuk meningkatkan akurasi dan kecepatan deteksi dengan algoritma Convolutional Neural Network (CNN). Penelitian ini dilakukan dalam beberapa tahapan yang terdiri dari data collection, image preprocessing, pembagian data latih dan data validasi, pembuatan model menggunakan CNN, dan evaluasi model. Model CNN dibuat untuk mengklasifikasikan gambar sel darah ke dalam dua kelas yaitu terinfeksi dan tidak terinfeksi. Dataset yang digunakan sebagai acuan dalam pembentukan model sistem deteksi menggunakan gambar sel darah dari sumber terbuka Kaggle sebanyak 11.312 gambar. Hasil evaluasi model CNN mendapatkan nilai akurasi sebesar 97.17% dalam mendeteksi gambar sel darah. Hasil tersebut menunjukkan bahwa model CNN yang dibentuk dapat digunakan untuk deteksi parasit malaria menggunakan gambar sel darah.

**Kata Kunci:** Convolutional Neural Network, Deep Learning, Malaria, Detection System

## Abstract

Microscopic examination is the most common malaria examination technique used in health facilities. However, microscopic examination requires special skills and quite a long time. This research aims to develop a malaria parasite detection system model in blood cell images using deep learning technology to increase the accuracy and speed of detection with the Convolutional Neural Network (CNN) algorithm. This research was carried out in several stages: data collection, image preprocessing, dividing training data and validation data, creating a model using CNN, and evaluating the model. A CNN model was created to classify blood cell images into two classes, namely infected and uninfected. The dataset used as a reference in forming a detection system model uses blood cell images from the open-source Kaggle as many as 11.312 images. The CNN model evaluation results obtained an accuracy value of 97.17% in detecting blood cell images. These results show that the CNN model created can be used to detect malaria parasites using blood cell images.

**Keywords:** Convolutional Neural Network, Deep Learning, Malaria, Detection System

## 1. Pendahuluan

Malaria merupakan salah satu penyakit yang menjadi perhatian di Kota Banjarmasin, Kalimantan Selatan. Komitmen pemerintah menangani kasus malaria sejalan dengan Keputusan Menteri Kesehatan Nomor 293 Tahun 2009 tentang Eliminasi Malaria pada tahun 2024 sebesar 405 kabupaten/kota di Indonesia dan Rencana Strategis Kementerian Kesehatan 2020-2024 [1]. Pada tahun 2023 terjadi peningkatan jumlah kasus positif malaria di Banjarmasin yaitu terdapat 164 kasus yang telah terkonfirmasi positif malaria berdasarkan hasil laboratorium dengan pemeriksaan mikroskopis dari 166 kasus suspek malaria yang dilaporkan [2].

Pemeriksaan mikroskopis adalah teknik pemeriksaan malaria yang paling umum digunakan di fasilitas Kesehatan. Dikenal sebagai salah satu pemeriksaan yang akurat dan murah, pemeriksaan ini memerlukan tenaga ahli untuk melakukannya. Adanya tenaga medis yang berpengalaman membuatnya mudah untuk menemukan parasite dalam sel darah. Namun, pemeriksaan mikroskopis memerlukan keahlian khusus dan waktu yang cukup lama. Pendeteksian parasit malaria menggunakan metode mikroskopis tradisional memerlukan waktu sekitar 30 hingga 60 menit, yang meliputi pengambilan sampel darah, persiapan dan pewarnaan sampel, serta pemeriksaan mikroskopis oleh teknisi laboratorium terlatih [3].

Berdasarkan permasalahan tersebut, pengembangan metode deteksi otomatis parasit malaria dalam citra sel darah menjadi sangat penting untuk mempercepat proses diagnosis dan meningkatkan akurasi hasil. Dalam konteks ini, teknologi *deep learning* telah menunjukkan potensi besar dalam memproses dan menganalisis data citra [4]. *Deep learning* merupakan salah satu bidang dari *machine learning* yang memanfaatkan jaringan syaraf tiruan untuk menyelesaikan permasalahan dengan dataset yang berukuran besar [5]. Metode *deep learning* telah menunjukkan hasil yang menjanjikan dalam berbagai bidang, termasuk pengenalan citra medis [6].

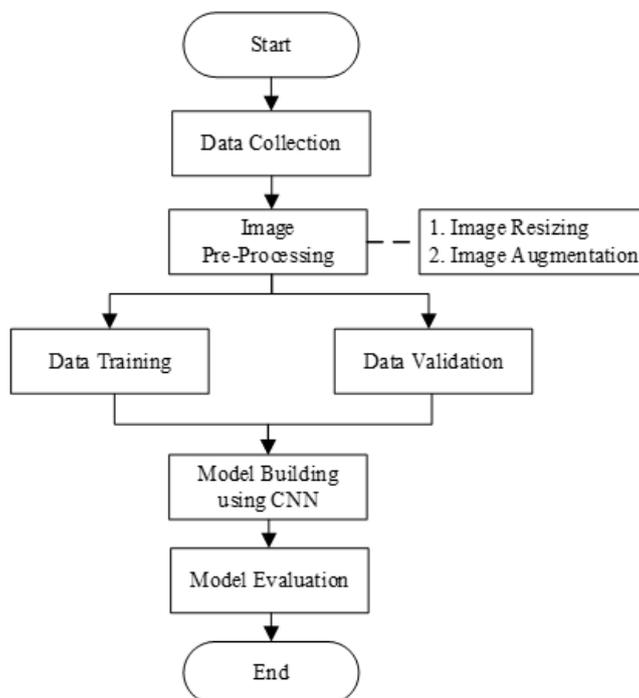
Seiring dengan perkembangan teknologi *Artificial Intelligence* (AI), penyakit malaria dapat dideteksi dengan menganalisis citra mikroskopis sel darah [3]. Pada citra mikroskopis sel darah, algoritma *deep learning* mampu mengenali pola dan fitur yang kompleks, yang sulit dideteksi oleh mata manusia. Penerapan AI khususnya dengan pendekatan dengan *deep learning*, telah banyak digunakan dalam melakukan tugas analisis citra medis, diantaranya deteksi penyakit Demam Berdarah [7], *Diabetic Retinopathy* [8], Tumor Otak [9], dan Cacar Monyet [10]. Penggunaan teknologi dalam deteksi penyakit melalui analisis gambar sel darah yang telah dilakukan oleh [7] menghasilkan metode dan sistem yang dapat mendiagnosis pasien Demam Berdarah dengan memanfaatkan citra apusan sel darah, sehingga dapat mempercepat proses diagnosis dan menghemat biaya.

Salah satu teknik yang dapat digunakan dalam membangun suatu sistem pendeteksian penyakit malaria adalah menggunakan kecanggihan teknologi *deep learning* dengan algoritma *Convolutional Neural Network* (CNN) yang memiliki keunggulan dalam pengenalan gambar visual yang lebih baik [11]. CNN merupakan salah satu algoritma yang ada pada *deep learning*. CNN memiliki cara kerja dengan menggunakan dataset gambar atau video sebagai masukannya. CNN sering digunakan untuk penelitian khususnya untuk mengklasifikasikan suatu studi kasus dengan objek gambar atau citra gambar, seperti citra CT Scan [12], tulisan tangan [13], sel darah [7], dan objek gambar lainnya. CNN menggunakan *Multi Layer Perceptron* (MLP) untuk memproses dan mengklasifikasikan citra gambar [14]. Arsitektur CNN terdiri atas satu layer input, output layer, dan *hidden layer*. Adapun lapisan tersembunyi biasanya merupakan bagian dari tiga layer utama yaitu lapisan *convolutional*, lapisan *pooling*, dan lapisan *fully connected* [15].

Pada penelitian ini, dirancang sebuah model deteksi parasit malaria yang menerapkan sistem *deep learning* menggunakan metode CNN. CNN telah terbukti memberikan hasil yang sangat baik dalam klasifikasi gambar dan telah banyak digunakan dalam penelitian sebelumnya dan memiliki hasil yang baik [16]. Penelitian lain yang menerapkan CNN menghasilkan akurasi sebesar 97,14% dalam klasifikasi data citra paru yang sehat dan terkena COVID-19 [17]. Dengan menggunakan *deep learning*, model pendeteksi parasit malaria dapat diimplementasikan pada perangkat *edge computing* (misalnya, *mobile devices* atau *embedded systems*). *Edge Computing* adalah paradigma teknologi baru dimana proses komputasi dan penyimpanannya terletak dekat dengan perangkat *mobile* atau sensor, sehingga pengolahan data di server tidak terlalu berat [18]. Penggunaan teknologi *edge computing* memungkinkan citra mikroskopis sel darah dapat diambil dan diproses langsung menggunakan kamera yang terhubung ke perangkat. Penyediaan sistem deteksi ini akan memungkinkan tenaga medis dan *researcher* melakukan diagnosis parasit malaria secara mandiri di laboratorium lapangan atau klinik sederhana.

## 2. Metode Penelitian

Penelitian ini dilakukan dalam beberapa tahapan yang terdiri dari *data collection*, *image preprocessing*, pembagian data latih dan data validasi, pembuatan model menggunakan CNN, dan evaluasi model. Langkah-langkah ini diilustrasikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Dataset citra sel darah yang digunakan pada penelitian ini diambil dari sumber data terbuka Kaggle sebanyak 11.312 gambar sel darah, dengan pembagian dapat dilihat pada Tabel 1. Dataset ini digunakan sebagai acuan pembentukan model sistem deteksi.

Tabel 1. Dataset

Image Category	Total Training	Total Validation
Parasite images	5043	1111
Uninfected images	4104	1054
<b>Total</b>	<b>9147</b>	<b>2165</b>

Data preprocessing dilakukan untuk mempersiapkan data mentah sebelum digunakan dalam model deep learning. Data preprocessing merupakan tahapan yang sangat penting karena data yang tidak diproses dengan baik dapat mengurangi kinerja model [19]. Dua hal yang dilakukan pada tahap ini yaitu *image resizing* dan *image augmentation*.

*Image Resizing* merupakan tahapan untuk mengubah ukuran suatu citra menjadi lebih besar atau kecil dari ukuran citra awal dengan ukuran yang telah ditetapkan sebelumnya. Hal ini bertujuan untuk mengurangi beban komputasi serta agar pemakaian memori penyimpanan lebih efisien. Ukuran gambar pada penelitian ini diubah menjadi 224x224 pixel, serta mengatur ukuran *batch* menjadi 64.

*Image augmentation* adalah manipulasi yang diterapkan pada gambar untuk membuat versi berbeda dari konten serupa guna memaparkan model ke lebih banyak contoh pelatihan. Sebelum dilakukan data augmentation, gambar hanya berjumlah satu, namun setelah proses *image*

*augmentation* diterapkan, jumlah gambar meningkat menjadi dua atau lebih dengan beberapa variasi seperti rotasi, pergeseran, atau pembesaran.

Manipulasi *image augmentation* adalah bentuk *image preprocessing*, namun terdapat perbedaan penting yaitu meskipun langkah *image preprocessing* diterapkan pada set pelatihan dan pengujian, *image augmentation* hanya diterapkan pada data pelatihan. Teknik ini membantu mencegah *overfitting* dan meningkatkan generalisasi model *deep learning* [20].

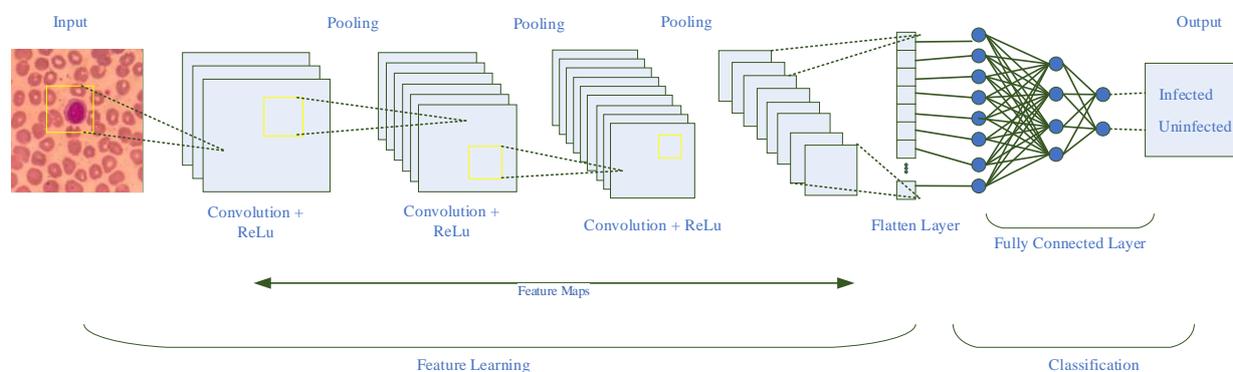
Dalam tahap ini dataset dibagi dengan rasio 80:20 dimana data latih 80% dan data validasi 20%. Pembagian dataset dilakukan secara manual dengan hati-hati untuk memastikan dataset terpisah secara acak dan proporsional. Dataset berjumlah 11.312 data gambar yang sudah dibagi menjadi 2 kelas yaitu “*Infected*” dan “*Uninfected*”, dengan masing kelas berjumlah 6.154 data untuk kelas “*Infected*” dan 5.158 data untuk kelas “*Uninfected*”. Setelah itu data dibagi dengan rasio 80% untuk data latih dan menghasilkan 9.147 data, serta 20% untuk data validasi dan menghasilkan 2.165 data. Detail pembagian data latih dan data validasi dapat dilihat pada Tabel 2.

**Tabel 2.** Pembagian Data Latih dan Data Validasi

Data	Amount of Data
Training Infected	5043
Training Uninfected	4104
Validation Infected	1111
Validation Uninfected	1054
<b>Total</b>	<b>Training = 9147</b> <b>Validation = 2165</b> <b>Dataset = 11312</b>

Perancangan model deteksi dibuat menggunakan algoritma CNN dengan model arsitektur layer *sequential*. Arsitektur CNN ini terdiri dari 2 lapisan, yaitu *feature learning* dan *classification layer* [21]. Arsitektur CNN pada penelitian ini diilustrasikan seperti pada Gambar 2.

Pada bagian *feature learning*, terdapat lapisan yang berfungsi untuk menerima input gambar secara langsung dan memprosesnya hingga menghasilkan output. Lapisan yang ada pada proses ini terdiri dari lapisan konvolusi dan lapisan *pooling*, dimana setiap proses lapisan tersebut akan menghasilkan *feature maps* untuk kemudian diteruskan pada bagian lapisan klasifikasi. *Convolutional Layer* merupakan lapisan dasar CNN, dimana lapisan ini mempelajari tepi, tekstur dan pola dari gambar yang dimasukkan., sedangkan *Pooling Layers* membantu mencegah *overfitting* dengan mengurangi jumlah parameter dan mengurangi dimensi spasial output lapisan konvolusi.



**Gambar 2.** Model Sekuensial CNN

Pada lapisan *classification*, terdiri dari beberapa lapisan yang berisi *neuron* yang terkoneksi penuh (*fully connected*) dengan lapisan lain (disebut juga *dense*). Lapisan ini menerima input dari *output layer* bagian *feature learning* yang kemudian diproses pada *flatten* dengan tambahan beberapa *hidden layer* pada *fully connected* hingga menghasilkan output berupa akurasi klasifikasi dari setiap kelas.

Informasi mengenai jenis layer, *output shape*, dan jumlah parameter dapat dilihat pada Tabel 3.

**Table 3.** Informasi Lapisan Model CNN

Layer (type)	Output Shape	Parameter
max_pooling2d	(none, 125, 125, 3)	0
conv2d	(none, 123, 123, 32)	896
max_pooling2d_1	(none, 61, 61, 32)	0
conv2d_1	(none, 59, 59, 64)	18,946
max_pooling2d_2	(none, 29, 29, 64)	0
conv2d_2	(none, 27, 27, 64)	36,928
max_pooling2d_3	(none, 13, 13, 64)	0
conv2d_3	(none, 11, 11, 64)	36,928
max_pooling2d_4	(none, 5, 5, 64)	0
Flatten	(none, 1600)	819,712
Dense	(none, 512)	1026
dense_1	(none, 2)	0

Pada layer pertama (*MaxPooling2D*) digunakan untuk mengurangi dimensi data spasial dimana ukuran dari (None, 250, 250, 3) menjadi (None, 125, 125, 3). Layer konvolusi (*Conv2D*) pada layer pertama digunakan untuk mengekstrak fitur dari gambar dengan menerapkan filter dan menghasilkan 32 filter dengan ukuran keluaran (none, 123, 123, 32) dan memiliki 896 parameter. *Layer MaxPooling2D* lainnya mengurangi ukuran gambar setelah konvolusi, sementara *layer Conv2D* berikutnya menambah kedalaman fitur dan parameter. Pada *Layer Flatten* meratakan data 2D menjadi 1D dengan output (None, 1600). *Layer Dense* kemudian menggunakan 819.712 parameter untuk klasifikasi dengan 512 unit, dan *Layer Dense* berikutnya menggunakan 1.026 parameter untuk keputusan akhir.

Evaluasi model dilakukan menggunakan *train generator* dan *validation generator* yang berfungsi untuk menghasilkan *batch* data validasi tanpa augmentasi. Secara otomatis, generator ini memproses data sesuai kebutuhan, termasuk penyesuaian ukuran gambar, normalisasi, dan penerapan augmentasi. Dengan memanfaatkan generator ini, pengelolaan data pelatihan dan validasi menjadi lebih sederhana dan efisien dalam bentuk batch, sehingga mendukung proses pelatihan model CNN secara optimal.

### 3. Hasil

Penelitian ini dilakukan menggunakan *Google Colab* dengan bahasa pemrograman Python. Untuk mengoptimalkan model dalam mendeteksi parasit pada gambar sel darah, dilakukan beberapa kali percobaan terhadap variasi nilai epoch. Dari beberapa kali percobaan, digunakan jumlah *epoch* 10 untuk melatih model CNN. Hasil dari evaluasi akurasi model dapat dilihat pada Tabel 4.

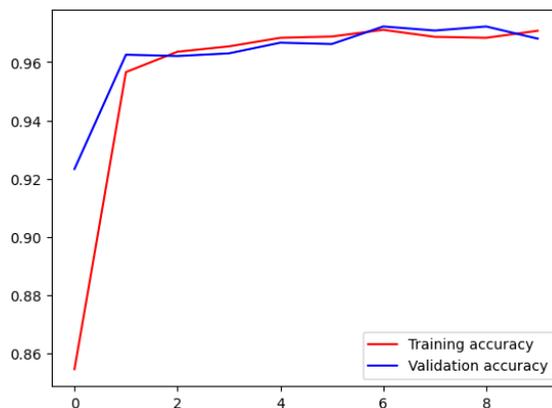
**Table 4.** Evaluasi Model

Iteration	Training		Validation	
	Accuracy (%)	Loss	Accuracy (%)	Loss
1	71.46	0.5359	89.46	0.2986
2	94.49	0.1714	95.33	0.1841
3	95.30	0.1416	96.58	0.1443
4	96.58	0.1112	96.35	0.1452

Iteration	Training		Validation	
	Accuracy (%)	Loss	Accuracy (%)	Loss
5	96.91	0.0985	96.49	0.1237
6	96.85	0.1038	96.58	0.1172
7	96.42	0.1031	96.77	0.1152
8	96.64	0.1006	96.40	0.1492
9	96.77	0.1024	96.81	0.1207
<b>10</b>	<b>97.17</b>	<b>0.0871</b>	<b>96.95</b>	<b>0.1118</b>

Pada iterasi pertama, akurasi pada data pelatihan (71.46%) masih cukup rendah, namun akurasi pada data validasi sudah tinggi (89.46%). Hal ini dikarenakan model baru mulai belajar pola dari data pelatihan. Pada iterasi 2-5, akurasi pelatihan dan validasi terus meningkat, sementara *loss* terus menurun. Hal ini menunjukkan bahwa model semakin baik dalam mempelajari pola dari data pelatihan dan generalisasi terhadap data validasi. Pada iterasi 6-10: model mencapai akurasi yang tinggi baik di data latih (sekitar 96-97%) maupun validasi (sekitar 96%), dengan *loss* yang semakin rendah. Hal ini menunjukkan model telah mencapai performa stabil, dan tidak ada perubahan signifikan dalam akurasi atau *loss* setelah seluruh iterasi.

Hasil evaluasi akurasi pelatihan and validasi dengan *epoch* 10 juga dapat dilihat pada Gambar 3.



**Gambar 3.** Akurasi Pelatihan dan Validasi

Dari hasil evaluasi model menunjukkan hasil yang cukup baik dengan akurasi 97.17%. Hasil akurasi validasi tetap tinggi dan stabil, serta *loss* validasi rendah, menunjukkan tidak ada *overfitting* yang berarti.

#### 4. Pembahasan

Model deteksi parasit malaria pada citra mikroskopis sel darah yang dikembangkan menggunakan *deep learning* dengan arsitektur *Convolutional Neural Network* (CNN) menunjukkan hasil yang memuaskan dengan tingkat akurasi sebesar 97,17%. Pencapaian ini menunjukkan bahwa model tersebut mampu mengidentifikasi parasit malaria dengan baik.

Proses *image augmentation* pada tahapan *image pre-processing* menjadi tahapan penting yang dapat mempengaruhi tingkat akurasi dari model ini. Hal ini juga telah dibuktikan pada penelitian [12] dimana ketika menerapkan augmentasi, model yang dikembangkan mendapatkan nilai akurasi yang tinggi dibandingkan jika tidak menggunakan augmentasi. Selain itu pemilihan parameter yang tepat dan penggunaan dataset yang representatif juga dapat mempengaruhi performa dari model ini.

Penelitian ini dapat memiliki potensi besar dalam penerapannya di dunia nyata. Dengan hasil akurasi yang sangat baik, diharapkan model deteksi ini dapat diimplementasikan pada perangkat

*edge computing*. Dengan penerapan teknologi ini, di masa mendatang tenaga medis di daerah endemik malaria dapat melakukan diagnosis parasit malaria secara mandiri di laboratorium lapangan atau klinik sederhana hanya dengan menggunakan kamera yang terhubung ke perangkat *edge computing*. Teknologi ini dapat menjadi solusi diagnostik yang andal, efisien, dan hemat biaya dalam penanganan malaria terutama di wilayah dengan keterbatasan akses terhadap fasilitas laboratorium dan tenaga ahli. Meskipun demikian, untuk mewujudkan hal tersebut terdapat tantangan teknis yang mungkin akan dihadapi pada penelitian-penelitian selanjutnya seperti optimasi model, penggunaan perangkat keras akselerasi, dan adaptasi terhadap kondisi lokal dapat meningkatkan keberhasilan implementasi.

## 5. Penutup

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model *deep learning* menggunakan algoritma CNN mampu mendeteksi parasit malaria menggunakan gambar citra sel darah dengan akurasi sebesar 97.17% dengan epoch 10. Dengan hasil akurasi yang cukup baik tersebut, diharapkan bahwa model sistem deteksi ini dapat diimplementasikan pada perangkat *edge computing* dan dipertimbangkan untuk uji klinis lapangan. Pada penelitian selanjutnya, dengan optimisasi yang tepat, sistem ini dapat menjadi solusi diagnostik yang andal, efisien, dan hemat biaya. Setelah proses verifikasi, sistem diharapkan dapat membantu berbagai pihak dalam melakukan deteksi dini penyakit malaria.

## Referensi

- [1] R. A. Sirait *et al.*, "Buletin APBN," *Buletin APBN*, vol. VIII, no. 23, Dec. 2023. [Online]. Available: <http://pa3kn.dpr.go.id/kontak>
- [2] Dinas Kesehatan Kota Banjarmasin, "Profil Kesehatan Tahun 2023 Kota Banjarmasin," Banjarmasin, 2024.
- [3] J. Fitriany and A. Sabiq, "Malaria," *Jurnal Averrous*, vol. 4, no. 2, 2018.
- [4] J. E. Massamba, J. C. Djontu, C. J. Vouvongui, C. Kobawila, and F. Ntoumi, "Plasmodium falciparum multiplicity of infection and pregnancy outcomes in Congolese women from southern Brazzaville, Republic of Congo," *Malar J*, vol. 21, no. 1, Dec. 2022, doi: 10.1186/s12936-022-04105-w.
- [5] J. Patterson and A. Gibson, *Deep Learning: A Practitioner's Approach*. 2017. [Online]. Available: [www.allitebooks.com](http://www.allitebooks.com)
- [6] A. W. Setiawan *et al.*, "Deteksi Malaria Berbasis Segmentasi Warna Citra dan Pembelajaran Mesin," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 4, pp. 769–776, Jul. 2021, doi: 10.25126/jtiik.2021844377.
- [7] W. Maulana Baihaqi, C. Raras, A. Widiawati, D. P. Sabila, and A. Wati, "Analisis Gambar Sel Darah Berbasis Convolution Neural Network untuk Mendiagnosis Penyakit Demam Berdarah," *Cogito Smart Journal |*, vol. 7, no. 1, 2021.
- [8] S. Rizal, N. Ibrahim, N. K. C. Pratiwi, S. Saidah, and R. Y. N. Fu'adah, "Deep Learning untuk Klasifikasi Diabetic Retinopathy menggunakan Model EfficientNet," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 8, no. 3, p. 693, Aug. 2020, doi: 10.26760/elkomika.v8i3.693.
- [9] A. Nada Nafisa, E. Nia Devina Br Purba, F. Aulia Alfarisi Harahap, and N. Adawiyah Putri, "Implementasi Algoritma Convolutional Neural Network Arsitektur Model MobileNetV2 dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary dan Meningioma," *Jurnal Teknologi Informasi, Komputer dan Aplikasinya (JTika)*, vol. 5, no. 1, pp. 53–61, Mar. 2023, [Online]. Available: <http://jtika.if.unram.ac.id/index.php/JTIKA/>
- [10] P. Sarah Fransisca and N. Matondang, "Deteksi Citra Digital Penyakit Cacar Monyet menggunakan Algoritma Convolutional Neural Network dengan Arsitektur MobileNetV2," *Jurnal Ilmu Komputer dan Agri-Informatika*, vol. 10, no. 2, pp. 200–211, 2023, [Online]. Available: <http://journal.ipb.ac.id/index.php/jika>

- [11] R. Soekarta, M. Yusuf, M. Fadli Hasa, and N. Annisa Basri, "Implementasi Deep Learning Untuk Deteksi Jenis Obat Menggunakan Algoritma CNN Berbasis Website," *JIKA (Jurnal Informatika)*, vol. 7, no. 4, pp. 455–464, Nov. 2023.
- [12] N. Sulaksono and A. Kurniawati, "Penerapan Artificial Intelligence dalam Mendeteksi Batu Ginjal secara Otomatis pada Citra CT Scan," *Jurnal Imejing Diagnostik*, vol. 10, pp. 42–46, 2024, [Online]. Available: <http://ejournal.poltekkes-smg.ac.id/ojs/index.php/jimed/index>
- [13] A. A. Handoko, M. A. Rosid, and U. Indahyanti, "Implementasi Convolutional Neural Network (CNN) Untuk Pengenalan Tulisan Tangan Aksara Bima," *SMATIKA JURNAL*, vol. 14, no. 01, pp. 96–110, Jul. 2024, doi: 10.32664/smatika.v14i01.1196.
- [14] A. Bagas Prakosa and dan Radius Tanone, "Implementasi Model Deep Learning Convolutional Neural Network (CNN) Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman," 2023. [Online]. Available: <https://www.kaggle.com/datasets/n>
- [15] S. Septhyan, R. Magdalena, and N. K. C. Pratiwi, "Deep Learning Untuk Deteksi Covid-19, Pneumonia, Dan Tuberculosis Pada Citra Rontgen Dada Menggunakan CNN Dengan Arsitektur Alexnet," *e-Proceeding of Engineering*, pp. 2869–2878, Dec. 2022.
- [16] Yohannes, S. Devella, and K. Arianto, "Deteksi Penyakit Malaria Menggunakan Convolutional Neural Network Berbasis Saliency," *JUITA: Jurnal Informatika*, vol. 8, no. 1, pp. 37–44, May 2020.
- [17] N. P. Wulandari and D. Fitriannah, "Analisa Perbandingan Algoritma CNN Dan MLP Dalam Mendeteksi Penyakit COVID-19 Pada Citra X-Ray Paru," *Sains, Aplikasi, Komputasi dan Teknologi Informasi*, vol. 3, no. 2, pp. 44–52, Aug. 2021.
- [18] A. A. Pratama, Y. Yohanie, F. Panduman, D. K. Basuki, and S. Sukaridhoto, "Edge Computing Implementation for Action Recognition Systems," *Scientific Journal of Informatics*, vol. 7, no. 2, pp. 2407–7658, 2020, [Online]. Available: <http://journal.unnes.ac.id/nju/index.php/sji>
- [19] N. Huda, S. Y. Prayogi, M. A. Ahmad, and A. Y. Dewi, "Klasifikasi Malaria Menggunakan Metode Image Processing Dari Sel Darah Merah Dengan Algoritma Convolutional Neural Network," *JOINS (Journal of Information System)*, vol. 7, no. 2, pp. 166–177, Nov. 2022, doi: 10.33633/joins.v7i2.7068.
- [20] D. P. Ayuni, Jasril, M. Irsyad, F. Yanto, and S. Sanjaya, "Augmentasi Data Pada Implemetasi Convolutional Neural Network Arsitektur Efficientnet-B3 Untuk Klasifikasi Penyakit Daun Padi," *ZONAsi: Jurnal Sistem Informasi*, vol. 5, no. 2, pp. 239–249, 2023.
- [21] K. Azmi, S. Defit, and U. Putra Indonesia YPTK Padang Jl Raya Lubuk Begalung-Padang-Sumatera Barat, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," vol. 16, no. 1, p. 2023.