

# **Sarana Pelaporan Angka Bebas Jentik dan Deteksi Jentik Nyamuk menggunakan Deep Learning**

**DIA BITARI MEI YUANA<sup>1</sup>, IRA AMELIA AGASTA<sup>2</sup>, MUHAMMAD ADI SAPUTRO<sup>3</sup>, ETIK AINUN ROHMAH<sup>4</sup>**

<sup>1,2,3</sup>Program Studi D4 Teknik Informatika, Politenik Negeri Jember

<sup>4</sup>Lembaga Penyakit Tropis, Universitas Airlangga

Email : [dia.bitari@polije.ac.id](mailto:dia.bitari@polije.ac.id)

*Received 16 April 2025 | Revised 16 Mei 2025 | Accepted 23 Mei 2025*

## **ABSTRAK**

*Demam Berdarah Dengue (DBD) masih menjadi masalah kesehatan utama di Indonesia. Kabupaten Jember mencatat 1.627 kasus pada tahun 2024, dengan Angka Bebas Jentik (ABJ) hanya mencapai rata-rata 92%, di bawah standar nasional >95%. Penelitian ini mengembangkan sistem deteksi jentik nyamuk otomatis menggunakan metode Deep Learning berbasis CNN dan GRU. Fitur visual diekstraksi melalui model InceptionV3, kemudian dianalisis secara sekuensial oleh GRU untuk klasifikasi larva. Hasil menunjukkan model mencapai akurasi pelatihan dan pengujian dengan performa optimal pada epoch ke-20 sebesar 99.19%, loss 0.0419. Jika dibandingkan dengan metode sebelumnya (AOA) yang hanya mencapai 84%, pendekatan ini terbukti lebih akurat dan tahan terhadap variasi kondisi data.*

**Kata kunci:** Demam Berdarah Dengue, *Aedes aegypti*, Angka Bebas Jentik, Deep Learning, Gated Recurrent Unit, Deteksi Otomatis

## **ABSTRACT**

*Dengue Hemorrhagic Fever (DHF) remains a major public health issue in Indonesia. In 2024, Jember Regency recorded 1,627 cases, with the Larvae Free Index (LFI) averaging only 92%, below the national standard of >95%. This study developed an automatic mosquito larvae detection system using a Deep Learning approach based on CNN and GRU. Visual features were extracted using the InceptionV3 model and then analyzed sequentially by the GRU for larval classification. The results showed that the model achieved optimal training and testing performance at the 20th epoch with 99.19% accuracy and a loss of 0.0419. Compared to the previous method AOA, which achieved only 84% accuracy, this approach proved to be more accurate and robust against variations in data conditions.*

**Keywords:** Dengue Hemorrhagic Fever, *Aedes aegypti*, Larvae-Free Rate, Deep Learning, Gated Recurrent Unit, Automated Detection

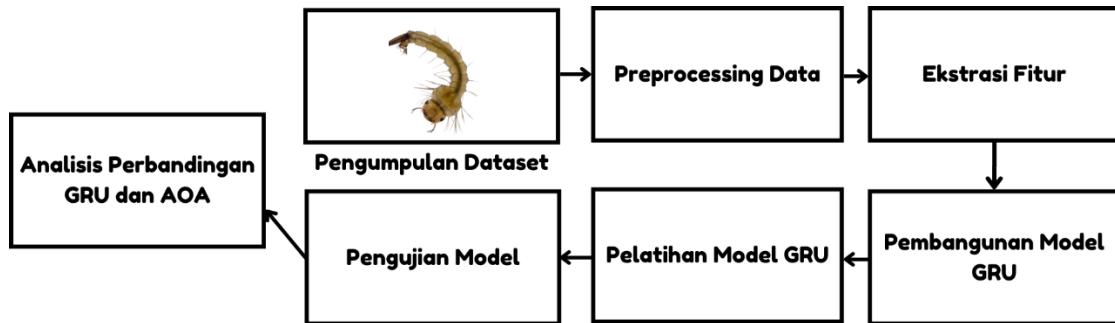
## 1. PENDAHULUAN

Demam berdarah dengue (DBD) merupakan penyakit demam akut yang disebabkan oleh virus dengue (**Noshirma et al., 2020**). Virus ini menginfeksi manusia lewat gigitan vektor nyamuk *Aedes Aegypti* yang berpotensi menyebabkan kematian apabila tidak dilakukan penanganan dengan baik. Penyakit ini masih menjadi isu kesehatan masyarakat di Indonesia termasuk yang tertinggi diantara negara-negara Asia Tenggara (**ayosehat.kemkes.go.id, 2025**). Secara keseluruhan, 114.720 kasus dengan 894 kematian dilaporkan pada tahun 2023. Pada minggu ke-43 tahun 2024, 210.644 kasus dengan 1.239 kematian dilaporkan akibat DBD di 259 kabupaten/kota di 32 provinsi. Hingga minggu ke-43, total 624.194 kasus dengue dilaporkan melalui SKDR (**kemkes.go.id, 2023**). Dinas Kesehatan Jawa Timur mencatat Kabupaten Jember memiliki jumlah kasus DBD tertinggi nomor 3 di tahun 2023 yaitu sebanyak 561 kasus dengan 9 kematian (**dinkes.jatimprov.go.id, 2024**). Pada minggu ke-17 tahun 2024 kasus DBD di Kabupaten Jember mencapai 1.109 kasus. Menurut Dinas Kesehatan Kabupaten Jember terdapat 5 kecamatan dengan kasus DBD tertinggi salah satunya yaitu kecamatan Patrang (**radarjember.net, 2024**). Dinas Kesehatan Kabupaten Jember mengatakan total pasien DBD di 2024 mencapai 1.627 kasus. Sementara pada minggu ke-2 di 2025 tercatat 293 kasus (**jatim.tribunnews.com, 2025**). Angka Bebas Jentik (ABJ) adalah indikator penting untuk pengendalian penyakit DBD. Pendataan ABJ dapat membantu melakukan identifikasi area berisiko tinggi terjadinya penyakit DBD sehingga memerlukan tindakan pencegahan (**Siregar et al., 2023**). Rata-rata ABJ di Kabupaten Jember pada tahun 2024 adalah 92% (**radarjember.net, 2024**). Sedangkan standar baku mutu pengendalian vektor nasional untuk DBD yang ditetapkan oleh Kementerian Kesehatan dalam pelaporan ABJ > 95% (**Lesmana & Halim, 2020**). Ini menunjukkan bahwa target pengendalian vektor DBD di Kabupaten Jember belum tercapai. Dinas Kesehatan Jember mencatat kendala seperti adanya kecamatan yang belum melaporkan angka bebas jentik secara berkala, ketidakakuratan pemeriksaan jentik dan keterbatasan pengetahuan kader dalam membedakan jentik dan bukan jentik, yang menghambat upaya pencegahan penyebaran penyakit DBD.

Keterbatasan-keterbatasan yang ada mendorong perlunya pendekatan teknologi yang lebih mutakhir. Penelitian terdahulu telah menggunakan algoritma *Average Optical Flow Algorithm* (AOA) berbasis video untuk mendeteksi pola gerak larva *Aedes aegypti*, dengan akurasi mencapai 84% dalam membedakan larva *Aedes* dan *Culex*. Penelitian ini menunjukkan potensi besar dalam mendukung otomatisasi deteksi skala besar dan menjadi landasan penting dalam memahami pola gerak larva sebagai identifikasi awal (**Yuana et al., 2020**). Pengetahuan tentang pola gerak larva ini dapat digunakan sebagai tahap segmentasi awal dalam proses deteksi. Selanjutnya, metode ini disempurnakan dengan implementasi *deep learning* menggunakan *Gated Recurrent Unit* (GRU). GRU dipilih karena kemampuannya yang unggul dalam menangani data sekuensial serta mampu mengatasi masalah *vanishing gradient* melalui mekanisme *update gate* dan *reset gate* (**Cho et al., 2014**). Selain itu, GRU memiliki komputasi yang lebih ringan dibandingkan dengan *Long Short Term Memory* (LSTM), sehingga lebih efisien dalam proses deteksi skala besar (**Ade Verilia et al., 2023**). Dibuktikan dengan penelitian terdahulu metode GRU dapat menghasilkan nilai akurasi 90.5% hingga 92.5% dalam mengklasifikasi aksi kekerasan dalam bentuk video (**Laksono & Matul, 2021**). Dengan pendekatan ini, diharapkan kemampuan deteksi pola gerak larva pada habitat alami dapat ditingkatkan secara signifikan. Meskipun belum ada studi langsung mengenai penerapan GRU untuk deteksi larva nyamuk, metode ini dipandang cocok untuk menangani pola gerak kompleks dan sekuensial dengan efektif. Tujuan penelitian ini adalah membantu meningkatkan akurasi pemeriksaan dengan menggunakan metode GRU dalam mendeteksi objek secara *real-time*, sebagai solusi efektif dalam mengendalikan populasi nyamuk.

## 2. METODE PENELITIAN

Tahapan penelitian yang dilakukan meliputi pengumpulan data untuk membangun dataset deteksi jentik nyamuk, *preprocessing* data guna mempersiapkan data yang optimal untuk proses pelatihan, ekstraksi fitur untuk mengidentifikasi pola gerak jentik, pelatihan model GRU untuk mendeteksi pola jentik dengan akurasi tinggi, pengujian performa model guna mengevaluasi ketepatan deteksi, serta analisis perbandingan antara metode GRU dan AOA. Hasil deteksi selanjutnya akan direkam dan disimpan dalam sistem untuk mendukung pemantauan berkelanjutan yang dapat dilihat Gambar 1.



**Gambar 1. Tahap Proses Deteksi GRU**

### 2.1. Dataset

Pengumpulan dataset video jentik difokuskan pada pengambilan data primer yang spesifik untuk mendeteksi jentik *Aedes aegypti*. Data primer diperoleh dengan merekam video jentik secara langsung menggunakan kamera dengan durasi 5-10 detik (**Sesulihati et al., 2020**). Tahap awal proses deteksi ini melibatkan segmentasi pola gerak jentik dengan menggunakan metode *Optical Flow*, yang telah terbukti efektif dalam mengidentifikasi perbedaan pola gerak larva.

Dataset video yang dikumpulkan diklasifikasikan ke dalam dua kelas, yaitu positif (terdeteksi jentik *Aedes*) dan negatif (tidak ada jentik *Aedes*). Pendekatan ini memastikan bahwa spesifikasi deteksi diarahkan secara khusus untuk identifikasi jentik *Aedes aegypti*, sebagaimana telah dijelaskan pada tahap segmentasi awal. Contoh dataset video jentik ditunjukkan pada Gambar 2.



**Gambar 2. Sampel Dataset Jentik**

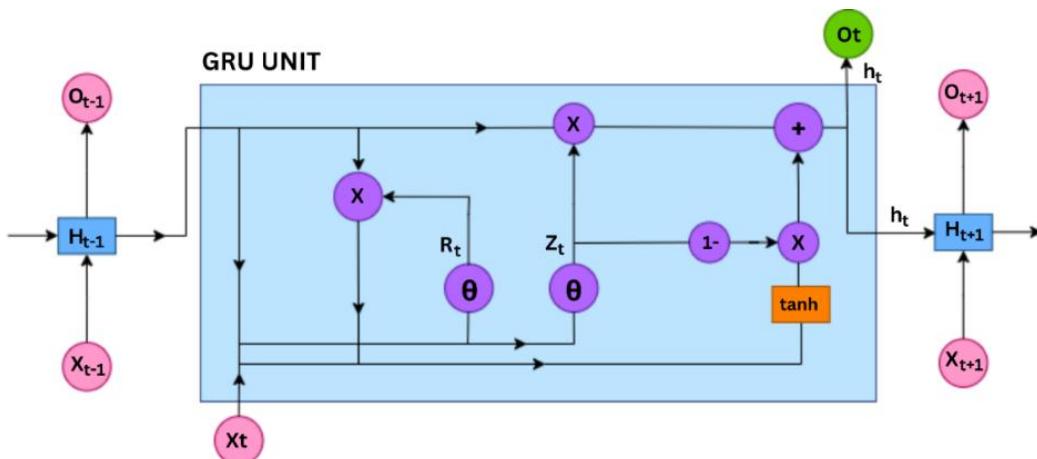
Proses awal yang dilakukan adalah mengelompokan antara data positif dan negatif. Setiap kelas memiliki masing-masing jumlah data yaitu 598 data positif dan 428 data negatif dengan total keseluruhan dataset adalah 1026 video jentik pada Tabel 1. Kemudian, data positif dan negatif tersebut disimpan ke dalam file CSV untuk memudahkan pengolahan data. Proses selanjutnya adalah membagi dataset menjadi data latih sebesar 80% dan data uji sebesar 20%.

**Tabel 1. Jumlah Dataset dan Pembagian Datanya**

<b>Jumlah Data</b>			
<b>Positif</b>	<b>Negatif</b>	<b>Data Latih</b>	<b>Data Uji</b>
598	428	820	206
<b>1026</b>			<b>1026</b>

## 2.2. Arsitektur Model GRU

*Gated Recurrent Unit* (GRU) adalah arsitektur yang diciptakan oleh Kyunghun Cho pada tahun 2014. Tujuan utama GRU adalah memungkinkan setiap *recurrent unit* dapat menangkap hubungan (dependensi) temporal dalam berbagai skala waktu secara adaptif. GRU memiliki komponen yang mengatur aliran informasi, yang disebut dengan *gate*, dan terdiri dari dua jenis *gate*, yaitu *reset gate* dan *update gate*. Struktur GRU digambarkan pada Gambar 3, di mana simbol  $r$  melambangkan *reset gate*,  $z$  melambangkan *update gate*, serta  $h$  dan  $\sim h$  melambangkan *activation* dan *candidate activation* (**Cho et al., 2014**).



**Gambar 3. Arsitektur GRU**

Untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting*, diterapkan *Dropout layer* pada arsitektur ini. *Overfitting* terjadi ketika model terlalu menyesuaikan diri dengan data latih sehingga kinerjanya menurun saat diuji dengan data baru. Model ini terdiri dari dua *hidden layer* dengan masing-masing 64 neuron, di mana *dropout* bekerja dengan menonaktifkan neuron secara acak selama pelatihan agar model tidak terlalu bergantung pada pola tertentu dalam data latih. Dengan demikian, model dapat belajar pola yang lebih umum dan tetap bekerja dengan baik pada data baru. Selama proses inferensi (prediksi), *Dropout* tidak diterapkan, sehingga semua neuron tetap aktif untuk menghasilkan *output* yang optimal (**Rismawandi et al., 2022**).

Selain *Dropout*, model ini juga menggunakan *Dense layer*, yang merupakan lapisan *fully connected* dalam jaringan saraf tiruan. *Dense layer* memainkan peran penting dalam

memetakan representasi fitur dari *hidden layer* ke *output model*. Setiap node dalam lapisan ini terhubung ke setiap node di lapisan berikutnya, sehingga memungkinkan pembelajaran yang lebih kompleks (**Josephine et al., 2021**). Perhitungan pada *Dense layer* dapat dirumuskan Persamaan (1):

$$\text{Output} = \text{activation}(\text{do}(\text{input}, \text{kernel}) + \text{bias}) \quad (1)$$

Salah satu fungsi aktivasi yang umum digunakan dalam *Dense layer* adalah ReLU (*Rectified Linear Unit*). Biasanya, lapisan ini berisi lapisan *Deeply Connected Neural Network* (DCNN). ReLU berfungsi untuk memperkenalkan non-linearitas ke dalam jaringan saraf, yang sangat penting dalam model deep learning seperti *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). ReLU didefinisikan Persamaan (2):

$$f(x) = \max(0, x) \quad (2)$$

Artinya, jika nilai *input*  $x$  negatif, output akan menjadi nol, sedangkan jika *input* bernilai positif, *output* tetap  $x$ . Keunggulan utama ReLU dibandingkan dengan fungsi aktivasi lain seperti *sigmoid* atau *tanh* adalah kemampuannya dalam mengatasi masalah *vanishing gradient*, sehingga model dapat berlatih lebih cepat dan lebih stabil (**Rismawandi et al., 2022**).

Pada lapisan *output*, digunakan fungsi aktivasi *Softmax* untuk mengubah logit menjadi probabilitas dalam tugas klasifikasi multikelas. Berbeda dengan *hidden layers* yang biasanya menggunakan ReLU untuk menangani non-linearitas, lapisan *output* menggunakan *Softmax* karena fungsi ini dapat menghasilkan distribusi probabilitas dari berbagai kelas. Fungsi aktivasi *Softmax* dirumuskan Persamaan (3):

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^N e^{z_j}} \quad (3)$$

Dengan menggunakan *Softmax*, model dapat menentukan probabilitas setiap kelas dalam tugas klasifikasi, sehingga kelas dengan probabilitas tertinggi akan dipilih sebagai *output* akhir (**Budianto et al., 2023**).

### 3. HASIL DAN PEMBAHASAN

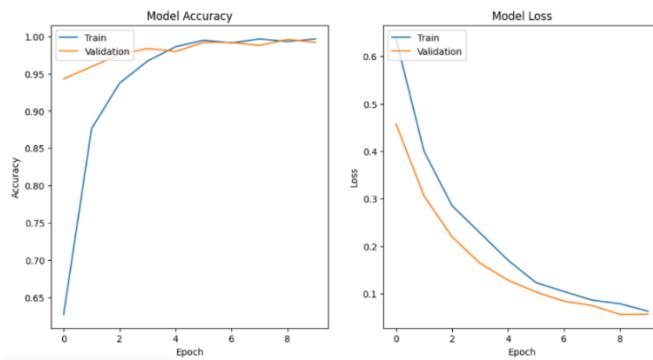
Tahap awal dimulai dengan memuat dataset berupa video menggunakan fungsi *load\_video()*, yang kemudian mengonversi video menjadi serangkaian *frame*. *Frame* tersebut dipotong di bagian tengah untuk menjaga proporsi gambar dengan menggunakan fungsi *crop\_center\_square()*. Ukuran *frame* kemudian disesuaikan menjadi 224x224 piksel dengan parameter *resize=(IMG\_SIZE, IMG\_SIZE)*. Kemudian setiap fitur dari *frame* diekstraksi menggunakan model *InceptionV3* yang telah dilatih sebelumnya dengan dataset *ImageNet*. Model ini menggunakan lapisan-lapisan konvolusional untuk mengidentifikasi fitur visual penting. Model *InceptionV3* diatur dengan parameter *include\_top=False*, yang berarti hanya lapisan-lapisan konvolusional hingga *layer pooling* terakhir yang digunakan untuk mengekstrak fitur, tanpa lapisan klasifikasi akhir. Hasil ekstraksi fitur menghasilkan vektor fitur berdimensi 2048 untuk setiap *frame* video. Proses ini memungkinkan model untuk mengidentifikasi pola visual dari setiap *frame* yang akan diolah lebih lanjut oleh model *Recurrent Neural Network* (RNN).

Dalam penelitian ini, tahap berikutnya memasukkan vektor-vektor fitur tersebut ke dalam model RNN dengan arsitektur model GRU untuk memproses data sekuensial dan melakukan klasifikasi berdasarkan pola dalam data. Model ini memiliki dua *input* utama, yaitu

*frame\_features\_input*, yang merepresentasikan fitur visual dari setiap *frame*, dan *mask\_input*, yang membantu model mengabaikan bagian sekuens yang tidak relevan. Struktur model terdiri dari dua lapisan GRU, di mana lapisan pertama memiliki 16 unit dengan *return\_sequences=True* untuk menangkap pola jangka panjang dalam data, sedangkan lapisan kedua dengan 8 unit hanya mempertahankan informasi yang paling relevan tanpa *return\_sequences*, menghasilkan satu vektor representasi akhir dari sekuens. Untuk meningkatkan performa model dan mencegah *overfitting*, digunakan lapisan *Dropout* sebesar 0.4, yang secara acak menonaktifkan beberapa neuron selama pelatihan agar model lebih general terhadap data baru. Setelah itu, lapisan *Dense* dengan 8 unit dan aktivasi ReLU digunakan untuk menangkap pola non-linear dalam data sebelum diklasifikasikan pada lapisan *output Dense* dengan aktivasi *Softmax*. Model ini dikompilasi menggunakan fungsi *loss sparse\_categorical\_crossentropy*, yang sesuai untuk klasifikasi multi-kelas, dan dioptimalkan dengan algoritma Adam agar proses pelatihan lebih stabil dan efisien.

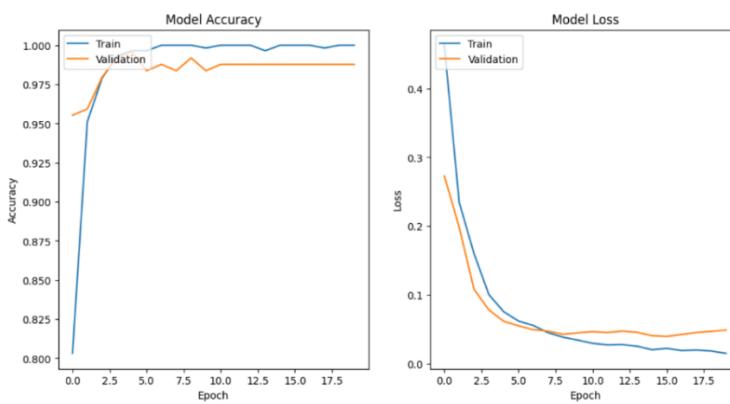
Model RNN yang terdiri dari dua lapisan GRU dilatih menggunakan dataset yang sudah diolah. Selama pelatihan, digunakan metrik akurasi dan *loss* untuk memantau kinerja model. Grafik di bawah menunjukkan kurva akurasi dan *loss* selama proses pelatihan dengan tiga jumlah epoch yang berbeda.

Grafik di bawah Gambar 4 menunjukkan kurva akurasi dan *loss* selama proses pelatihan selama 10 epoch.



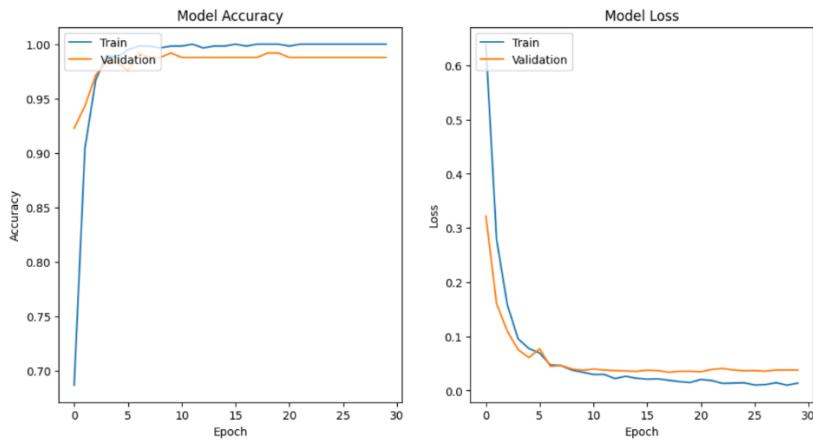
**Gambar 4. Epoch 10**

Grafik di bawah Gambar 5 menunjukkan kurva akurasi dan *loss* selama proses pelatihan selama 20 epoch.



**Gambar 5. Epoch 20**

Grafik di bawah Gambar 6 menunjukkan kurva akurasi dan *loss* selama proses pelatihan selama 30 epoch.

**Gambar 6. Epoch 30**

Berdasarkan analisis hasil model pada jumlah epoch 10, 20, dan 30, jumlah epoch yang paling baik adalah 20 epoch. Pada epoch ke-10, model menunjukkan akurasi sebesar 85.47%, namun nilai *loss* yang tinggi (0.113) mengindikasikan bahwa model masih berada dalam fase *underfitting* dan belum mampu menangkap pola secara optimal dari dataset. Pada epoch ke-20, model mencapai kondisi optimal dengan akurasi yang meningkat secara signifikan menjadi 99.19% dan nilai *loss* yang rendah (0.0419). Pada titik ini, model telah mempelajari pola dataset dengan baik dan tetap menjaga generalisasi tanpa indikasi *overfitting*.

Sementara itu, pada epoch ke-30, meskipun akurasi meningkat sedikit menjadi 99.38%, mulai terlihat indikasi *overfitting*. Nilai *loss* tidak lagi mengalami penurunan signifikan, dan performa validasi menunjukkan potensi penurunan, menandakan bahwa model mulai kehilangan kemampuannya untuk bekerja dengan baik pada data baru. Oleh karena itu, epoch ke-20 adalah pilihan terbaik karena memberikan keseimbangan antara akurasi tinggi dan nilai *loss* rendah, sekaligus menghindari risiko *overfitting*.

Model RNN yang telah dilatih kemudian diuji menggunakan dataset pengujian. Setiap video diuji berdasarkan probabilitas dari masing-masing kategori yang telah dipelajari. Tabel 2 menyajikan beberapa contoh hasil prediksi beserta probabilitas setiap kelas.

**Tabel 2 Probabilitas Prediksi dan Akurasi Model**

No	Video ID	Kategori Aktual	Kategori Prediksi	Probabilitas Kategori Prediksi (%)	Probabilitas Kategori Lain (%)	Akurat (Ya/Tidak)
1.	Vid001	Kategori 0	Kategori 0	95.53%	1 : 4.47%	YA
2.	Vid002	Kategori 1	Kategori 1	97.07%	0 : 2.93%	YA
3.	Vid003	Kategori 0	Kategori 0	95.63%	1 : 4.37%	YA
4.	Vid004	Kategori 0	Kategori 0	95.79%	1 : 4.21%	YA
5.	Vid005	Kategori 0	Kategori 0	95.74%	1 : 4.26%	YA
6.	Vid006	Kategori 0	Kategori 0	95.67%	1 : 4.33%	YA
7.	Vid007	Kategori 0	Kategori 0	95.62%	1 : 4.38%	YA
8.	Vid008	Kategori 1	Kategori 1	97.23%	0 : 2.77%	YA
9.	Vid009	Kategori 0	Kategori 0	95.69%	1 : 4.31%	YA
10.	Vid010	Kategori 1	Kategori 1	97.17%	0 : 2.83%	YA

Hasil prediksi menunjukkan bahwa model berhasil mengklasifikasikan video dengan tingkat akurasi rata-rata sebesar 96.02% pada set pengujian. Berdasarkan hasil yang diperoleh, model

RNN dengan arsitektur GRU menunjukkan akurasi yang kompetitif dalam mengklasifikasikan aksi pada video. Dengan konvergensi yang lebih cepat dibandingkan dengan model lain seperti LSTM, model ini mampu menghasilkan klasifikasi yang akurat pada data pengujian. Penggunaan *InceptionV3* sebagai ekstraktor fitur juga memberikan representasi fitur yang lebih baik, yang berkontribusi pada akurasi tinggi.

Metode yang digunakan memiliki beberapa kelebihan, di antaranya adalah komputasi yang lebih ringan. GRU memiliki jumlah parameter yang lebih sedikit dibandingkan dengan LSTM, sehingga waktu pemrosesan menjadi lebih cepat. Selain itu, ekstraksi fitur yang kuat juga menjadi kelebihan model ini, karena *InceptionV3* mampu menangkap pola visual yang signifikan dari setiap *frame*, yang pada gilirannya meningkatkan akurasi klasifikasi secara keseluruhan. Namun, terdapat beberapa kekurangan yang perlu diperhatikan. Salah satunya adalah keterbatasan panjang sekuens. Pengaturan panjang maksimum sekuens (MAX\_SEQ\_LENGTH) menyebabkan frame yang melebihi panjang ini terpotong, yang berisiko menghilangkan informasi penting. Selain itu, model juga sangat bergantung pada dataset yang digunakan. Akurasi model akan menurun jika dataset tidak cukup representatif, terutama ketika dihadapkan dengan data yang tidak dikenal.

#### **4. KESIMPULAN**

Berdasarkan hasil penelitian, dengan memanfaatkan fitur yang diekstraksi oleh model CNN *InceptionV3* dan pemrosesan sekuens oleh model RNN GRU, model ini dapat memberikan hasil klasifikasi yang akurat dan efisien untuk deteksi jentik nyamuk. Model yang dikembangkan berhasil mencapai akurasi pelatihan sebesar 96.02% dan akurasi pengujian sebesar 96.02% dengan menggunakan data sebanyak 1026, learning rate 0.01, dan epoch maksimum 20. Pada uji dengan tiga jumlah epoch yang berbeda (10, 20, dan 30), model menunjukkan performa terbaik pada epoch ke-20, dengan akurasi 99.19% dan nilai *loss* yang rendah (0.0419), menandakan kondisi optimal tanpa *overfitting*. Pada epoch ke-10, akurasi hanya mencapai 85.47% dengan nilai *loss* tinggi (0.113), menunjukkan *underfitting*, sementara pada epoch ke-30 meskipun akurasi sedikit meningkat menjadi 99.38%, indikasi *overfitting* mulai muncul. Dengan demikian, epoch ke-20 dipilih sebagai yang terbaik karena memberikan keseimbangan antara akurasi tinggi dan nilai *loss* rendah. Hasil ini menunjukkan bahwa model GRU mampu mengidentifikasi jentik nyamuk dengan tingkat keakuratan yang baik, bahkan pada kondisi pencahayaan dan latar belakang yang bervariasi. Jika dibandingkan dengan penelitian sebelumnya yang menggunakan algoritma *Average Optical Flow Algorithm* (AOA) berbasis video, yang hanya mencapai akurasi 84% dalam membedakan larva *Aedes* dan *Culex*, model berbasis CNN-GRU ini menunjukkan peningkatan signifikan dalam akurasi dan ketahanan terhadap variasi kondisi data. Hal ini membuktikan bahwa pendekatan *deep learning* yang diusulkan lebih unggul dalam mendekripsi jentik nyamuk secara otomatis dan efisien.

#### **UCAPAN TERIMA KASIH**

Kami mengucapkan penghargaan dan terima kasih kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi Republik Indonesia, khususnya Direktorat Jenderal Pendidikan Vokasi, atas dukungan dana yang diberikan melalui Program Kreativitas Mahasiswa Pengabdian Masyarakat (PM). Ucapan terima kasih juga kami sampaikan kepada Politeknik Negeri Jember beserta para pembimbing, serta pihak Dinas Kesehatan Jember dan Puskesmas Patrang, atas segala bantuan dan dukungan dalam pelaksanaan program ini. Dukungan dari semua pihak sangat berarti bagi keberhasilan program ini.

## DAFTAR RUJUKAN

- Verilia, A. F., Firdaus, R., & Dian Septama, H. (2023). Pengembangan Pengenalan Aktivitas Manusia Secara Real Time Menggunakan Metode Convolutional Neural Network dan Deep Gated Recurrent Unit. *Jurnal Ilmiah Multidisiplin*, 2(2).
- ayosehat.kemkes.go.id. (2025). Demam Berdarah Dengue. <https://ayosehat.kemkes.go.id/topik/demam-berdarah-dengue>
- Budianto, W., Herwindiati, D. E., & Hendryli, J. (2023). Pengenalan Bentuk Wajah Dengan Metode Convolutional Neural Network Untuk Pemilihan Model Kacamata Secara Online. *Infotech: Journal of Technology Information*, 9(2), 129–136. <https://doi.org/10.37365/jti.v9i2.176>
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). *Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation*. <http://arxiv.org/abs/1406.1078>
- dinkes.jatimprov.go.id. (2024). Profil Kesehatan Provinsi Jawa Timur Tahun 2023. [https://dinkes.jatimprov.go.id/index.php?r=site/file\\_list&id\\_file=10&id\\_berita=8](https://dinkes.jatimprov.go.id/index.php?r=site/file_list&id_file=10&id_berita=8)
- Helen Josephine, V. L., Nirmala, A. P., & Alluri, V. L. (2021). Impact of Hidden Dense Layers in Convolutional Neural Network to enhance Performance of Classification Model. *IOP Conference Series: Materials Science and Engineering*, 1131(1), 012007. <https://doi.org/10.1088/1757-899x/1131/1/012007>
- jatim.tribunnews.com. (2025). Awal 2025, Ada 293 Kasus DBD di Jember, 56 Orang Positif dan Satu Meninggal Dunia. <https://jatim.tribunnews.com/2025/01/18/awal-2025-ada-293-kasus-dbd-di-jember-56-orang-positif-dan-satu-meninggal-dunia>
- kemkes.go.id. (2023). Waspada Penyakit Musim Hujan. <https://kemkes.go.id/id/waspada-penyakit-di-musim-hujan>
- Laksono, I. K., & Matul, E. (2021). *The Journal on Machine Learning and Computational Intelligence (JMLCI) Deteksi Kekerasan pada Pertandingan Hockey Menggunakan Algoritma Gated Recurrent Unit*.
- Lesmana, O., & Halim, R. (2020). Gambaran Tingkat Kepadatan Jentik Nyamuk Aedes Aegypti Di Kelurahan Kenali Asam Bawah Kota Jambi. Density Level Of Aedes Aegypti Mosquito Description in Kenali Asam Bawah District, Jambi City. In *Jurnal Kesmas Jambi* (Vol. 4, Issue 2). JK MJ.
- Noshirma, M., Willa, R. W., Kazwaini, M., & Wibowo, A. (2020). Deteksi Virus Dengue pada Nyamuk Aedes aegypti (Diptera: Culicidae) yang Tersebar di Kabupaten Sumba Timur

- dan Sumba Barat Daya. *Jurnal Vektor Penyakit*, 14(1), 57–64.  
<https://doi.org/10.22435/vektorp.v14i1.2421>
- radarjember.net. (2024). *ribuan-kasus-dbd-di-jember-ini-kata-kepala-dinas-kesehatan-jember*. <https://radarjember.net/posts/ribuan-kasus-dbd-di-jember-ini-kata-kepala-dinas-kesehatan-jember>
- Rismawandi, R. I Gede Pasek Suta Wijaya, & Gibran Satya Nugraha. (2022). Implementasi Metode Convolutional Neural Network Untuk Penegenalan Huruf Aksara Sasak Pada Android (*Implementation Convolutional Neural Network Method for Recognition of Sasak Characters in Android*). <http://jtiika.if.unram.ac.id/index.php/JTIKA/>
- Sesulihatien, W. T., Yuana, D. B. M., Basuki, A., Harsono, T., Alimudin, A., & Rohmah, E. A. (2020). Mobile sensing in aedes aegypti larva detection with biological feature extraction. *Bulletin of Electrical Engineering and Informatics*, 9(4), 1454–1460.  
<https://doi.org/10.11591/eei.v9i4.1993>
- Siregar, S., Mulyani, S., Rizky, V. A., Akmal, D., & Sutriyawan, A. (2023). Pengaruh Keberadaan Jentik dan Perilaku 3M Plus terhadap Kejadian Demam Berdarah Dengue. *Jurnal Kesehatan Komunitas (Journal of Community Health)*, 9(3), 456–463.  
<https://doi.org/10.25311/keskom.vol9.iss3.1392>
- Yuana, D. B. M., Sesulihatien, W. T., Basuki, A., Harsono, T., Alimudin, A., & Rohmah, E. A. (2020). Mobile sensing in aedes aegypti larva detection with biological feature extraction. *Bulletin of Electrical Engineering and Informatics*, 9(4), 1454–1460.  
<https://doi.org/10.11591/eei.v9i4.1993>