

KLASIFIKASI SUARA NYAMUK BERBASIS CNN (CONVOLUTIONAL NEURAL NETWORK) UNTUK INOVASI PENGENDALIAN HAMA DAN PENYAKIT

Ardoni Yeriko Rifana Gultom¹, Rika Ajeng Finatih², Ignatius Krisna Issaputra³, M. Gilang Martiansyah⁴, Sasa Rahma Lia⁵, Nazwa Nabilla⁶, Ardika Satria⁷

^{1,3}Teknik Informatika, Institut Teknologi Sumatera, Lampung Selatan, Indonesia.

^{2,4,5,6,7}Sains Data, Institut Teknologi Sumatera, Lampung Selatan, Indonesia.

*Penulis korespondensi: rika.121450036@student.itera.ac.id

ABSTRAK

Isu kesehatan terkait dengan penyakit yang disebarkan oleh nyamuk yakni demam berdarah dengue (DBD), malaria, chikungunya, dan filariasis merupakan permasalahan global yang sangat mengkhawatirkan terkhusus di kawasan tropis seperti Indonesia. Pemerintah telah mengupayakan pengendalian nyamuk seperti kampanye 3M+ (Menguras, Menutup, Mendaur Ulang) dan penggunaan insektisida, tetapi masih kurang efektif. Riset ini mengeksplorasi pemanfaatan teknologi untuk mengendalikan nyamuk vektor dengan mengidentifikasi suara kepakan sayapnya menggunakan teknik *Convolutional Neural Network* (CNN). Audio dari tiga spesies nyamuk berbeda digunakan yakni: *Aedes aegypti*, *Anopheles stephensi*, dan *Culex pipiens*. Fitur yang diekstrak meliputi *Mel-Frequency Cepstral Coefficients* (MFCC) dan *Mel-Spectrogram*. Model CNN dirancang dengan lima blok konvolusi dengan filter 32, 64, 128, 256, 512, kernel 3x3, diikuti *Max Pooling* 2x2, regularisasi L2 (0,01), dan *dropout* (0,3 hingga 0,45) untuk mengurangi *overfitting*. Pelatihan dilakukan selama 100 *epoch* dengan *batch size* 32. Hasil evaluasi menunjukkan akurasi model sangat baik mencapai 98%, dengan nilai *f1-score* setiap *class* mencapai 0.98. Harapannya, teknologi ini mampu mendukung program eliminasi malaria dan filariasis pada tahun 2030 serta menurunkan insiden DBD di Indonesia dan mempercepat deteksi serta penanganan penyakit yang ditularkan oleh nyamuk sejalan dengan pendekatan *One Health* yang menghubungkan kesehatan manusia, hewan, dan lingkungan.

Kata kunci: Klasifikasi Suara Nyamuk, CNN, Pengendalian Vektor, Penyakit Tropis, *One Health*.

1 PENDAHULUAN

Penanggulangan penyakit nyamuk telah menjadi isu global yang menuntut adanya inovasi berkelanjutan. *World Health Organization* (WHO) mencatat jutaan orang terinfeksi penyakit ini tiap tahun, sehingga berdampak signifikan pada kesehatan dan perekonomian masyarakat khususnya di daerah dengan kawasan tropis (Jaehoon et al., 2021). Indonesia merupakan salah satu negara tropis yang menghadapi risiko kesehatan cukup besar akibat penyakit yang disebabkan oleh nyamuk, diantaranya demam berdarah dengue (DBD), malaria, chikungunya, dan filariasis. Kelompok penyakit ini menimbulkan beban kesehatan masyarakat yang sangat mengkhawatirkan (Kemenkes, 2021).

Berdasarkan data Kementerian Kesehatan tahun 2022, Indonesia mengalami lebih dari 100.000 kasus demam berdarah dengue (DBD) dengan angka kematian yang signifikan di sejumlah daerah endemis (Pratiwi, 2024). Disamping itu, malaria masih menjadi permasalahan kesehatan di 236 kabupaten/kota di Indonesia, khususnya di wilayah timur seperti Papua dan Nusa Tenggara Timur

yang memiliki tingkat endemisitas tinggi (Kemenkes, 2021). Berbagai upaya pengendalian vektor nyamuk telah dilakukan, seperti kampanye 3M+ (Menguras, Menutup, Mendaur Ulang) dan penggunaan insektisida, tetapi masih saja ditemukan kendala yang cukup signifikan. Faktor lingkungan, perubahan iklim, serta urbanisasi yang terus meningkat memberikan dampak buruk pada penyebaran nyamuk sehingga membuat metode konvensional yang dijalankan menjadi kurang efektif (Pratiwi, 2024). Menjawab tantangan ini, diperlukan sebuah terobosan teknologi yang mampu meningkatkan strategi pengendalian vektor secara komprehensif dan efisien.

Sejalan dengan perkembangan teknologi terkini, metode berbasis *deep learning* seperti *Convolutional Neural Network* (CNN) muncul sebagai solusi efektif dalam mengatasi permasalahan tersebut. CNN yang awalnya diperuntukkan dalam menganalisis gambar, kini pun dapat digunakan dalam mengelola sinyal audio termasuk kepaan sayap nyamuk. Teknologi ini dapat mempermudah proses identifikasi jenis nyamuk dengan cepat dan akurat, sehingga memungkinkan respons pengendalian yang lebih tepat sasaran. Misalnya, dengan mengidentifikasi pola suara spesifik dari nyamuk *Aedes Aegypti*, *Anopheles Stephensi*, atau *Culex Pipiens*, dengan melakukan tindakan pencegahan yang dapat disesuaikan berdasarkan spesies dan perilakunya (Pratiwi, 2024).

Pada analisis audio suara kepaan nyamuk, teknik penting yang digunakan penelitian meliputi ekstraksi fitur dengan memanfaatkan *Mel-Frequency Cepstral Coefficients* (MFCC) dan *Mel-Spectrogram*. MFCC menangkap sifat frekuensi suara yang sensitif terhadap perubahan frekuensi rendah, sedangkan *Mel-Spectrogram* menyajikan perubahan frekuensi secara visual dari waktu ke waktu (Permana et al., 2023). Kombinasi dari kedua fitur tersebut memfasilitasi model CNN dalam mengidentifikasi spesies nyamuk melalui suara kepaan sayapnya dengan akurasi tinggi, bahkan dengan lingkungan yang bising (Jaehoon et al., 2021).


Studi yang pernah dilakukan oleh Jaehoon et al., berhasil mengidentifikasi ciri unik sinyal audio nyamuk yang dapat membedakan spesiesnya dengan menggunakan jaringan *Convolutional Neural Network* (CNN) dengan mengubah sinyal audio menjadi spektogram yang memungkinkan CNN dapat mengidentifikasi pola frekuensi dan waktu secara otomatis berhasil (Jaehoon et al., 2021). Studi ini menunjukkan bahwa model CNN berbasis VGG16 dapat mengklasifikasi spesies nyamuk dengan akurasi sebesar 85,7% menggunakan fitur *Mel-Frequency Cepstral Coefficients* (MFCC) yang diekstrak dari rekaman suara (Jaehoon et al., 2021). Studi serupa juga dilakukan oleh Fernandes et al., meneliti terkait identifikasi nyamuk *Aedes aegypti* melalui rekaman audio dengan memanfaatkan jaringan saraf konvolusional (CNN). Model CNN mencapai akurasi 97% dan *F1-measure* 89% dalam mendeteksi *Aedes aegypti* dari rekaman suara *smartphone*. Pendekatan model ansambel memberikan sensitivitas tertinggi dengan tingkat keberhasilan deteksi mencapai 96% (Fernandes et al., 2021). Temuan-temuan ini menunjukkan bahwa teknologi memberikan pendekatan yang ampuh bila diaplikasikan secara luas melalui perangkat portabel atau aplikasi *Internet of Things* (IoT) dan memperkuat kesadaran masyarakat tentang tempat berkembang biaknya nyamuk dan mendukung upaya pemberantasannya di lingkungan sekitar.

Penelitian ini bertujuan untuk mendesain model berbasis jaringan *Convolutional Neural Network* (CNN) untuk klasifikasi suara nyamuk guna mengoptimalkan pengendalian vektor penyakit. Model ini memungkinkan identifikasi otomatis spesies nyamuk terutama *Aedes Aegypti*, *Anopheles Stephensi*, dan *Culex Pipiens* berdasarkan pola frekuensi suara unik mereka. Inovasi

tersebut diharapkan dapat berkontribusi pada upaya pengendalian nyamuk, yang sejalan dengan prinsip *One Health* dengan menghubungkan kesehatan manusia, hewan, dan lingkungan (Kemenkes, 2021). Teknologi ini juga mendukung program pemerintah untuk mengeliminasi malaria dan filariasis pada tahun 2030 serta mengurangi insiden demam berdarah dengue (DBD) di bawah 49 kasus per 100.00 jiwa (Kemenkes, 2021).

2 METODE

Tahapan analisis data audio dalam membangun model CNN meliputi beberapa langkah utama yang dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Data

Penelitian ini memanfaatkan data primer dari Proyek Abuzz yang terdiri dari 1.285 rekaman audio suara kepankan sayap dari 23 spesies nyamuk (Mukundarajan et al., 2018). Dataset yang bersifat terbuka ini dapat diakses pada situs resmi "datadryad.org". Data tersebut dikumpulkan menggunakan delapan jenis ponsel berbeda, termasuk ponsel pintar (misalnya, iPhone 4S, Xperia Z3 Compact) dan ponsel fitur kelas bawah (misalnya, Samsung SGH T-209). Rekaman dilakukan terutama pada nyamuk yang terbang bebas di lapangan, baik dengan metode mengikuti pergerakannya maupun dengan menangkapnya dalam wadah (Mukundarajan et al., 2018). Karakteristik data audio diringkas pada Tabel 1.

Tabel 1. Karakteristik dataset yang digunakan dalam pengembangan model CNN

Spesies	Jumlah File	Durasi Original (Menit)
<i>Aedes aegypti</i>	22	1736.87
<i>Aedes albopictus</i>	7	966.37
<i>Aedes mediovittatus</i>	3	180.00
<i>Aedes sierrensis</i>	361	3337.58
<i>Anopheles albimanus</i>	40	1736.55
<i>Anopheles arabiensis Dongola</i>	6	1040.11
<i>Anopheles arabiensis rufisque</i>	7	943.76
<i>Anopheles atroparvus</i>	7	907.64
<i>Anopheles dirus</i>	65	1733.48
<i>Anopheles farauti</i>	47	1727.52
<i>Anopheles freeborni</i>	54	2397.82
<i>Anopheles gambiae akron</i>	7	972.98
<i>Anopheles gambiae Kisumu</i>	57	1747.59
<i>Anopheles gambiae rsp</i>	2	567.66
<i>Anopheles merus</i>	5	300.00
<i>Anopheles minimus</i>	68	2923.11
<i>Anopheles quadriannulatus</i>	7	1178.10
<i>Anopheles quadrimaculatus</i>	6	665.71
<i>Anopheles stephensi</i>	58	2909.69
<i>Culex pipiens</i>	9	710.37
<i>Culex quinquefasciatus</i>	13	758.13
<i>Culex tarsalis</i>	12	613.87
<i>Culiseta incidens</i>	37	2971.58

Tabel 1 menyajikan ringkasan jumlah rekaman dan durasi total per spesies dalam data awal. Dari 23 spesies yang tersedia, penelitian ini berfokus pada tiga spesies saja yakni: *Aedes aegypti*, *Anopheles stephensi*, dan *Culex pipiens*. Pemilihan spesies tersebut didasari oleh prevalensi di Indonesia sebagai negara tropis yang memiliki risiko tinggi penyakit nyamuk, seperti demam berdarah dengue (DBD), malaria, chikungunya, dan filariasis (Kemenkes, 2021).

Penelitian ini memanfaatkan tools pustaka *Python*, meliputi *librosa* (untuk manipulasi audio), *numpy* (untuk perhitungan ilmiah), dan *matplotlib* (untuk visualisasi). Rekaman diperoleh menggunakan ponsel yang beragam dan dalam berbagai format (WAV, MP4, M4A, AMR), sehingga menimbulkan variasi dalam durasi dan frekuensi pengambilan sampel, sebagaimana ditunjukkan dalam Gambar 1.

2.2 Praproses Audio

Dalam mengekstrak fitur, rekaman audio perlu dilakukannya praproses. Penelitian ini dilakukan dua praproses yaitu cara manual dan otomatis dengan menggunakan bantuan *library librosa* untuk mengekstrak fitur. Praproses manual dilakukan *noise removal* dengan bantuan *adobe audition* dalam menghapus suara *noise* dari audio kepaan nyamuk. Selanjutnya, audio disegmentasikan menjadi potongan-potongan berdurasi 3 detik. Kemudian audio yang sudah dipotong kedalam segmen tersebut dilakukan pengecekan dengan menghapus audio yang tidak mengandung suara kepaan nyamuk.

Masih dalam tahapan yang sama, dengan menggunakan bantuan *library librosa* dilakukan kembali *augmentasi* audio untuk memperkaya variasi data audio, dimana dalam tahapan ini dilakukan penambahan *noise* dengan amplitudo 5×10^{-3} , *pitch shifting* dengan mengatur *pitch* (nada) dari audio dengan jumlah langkah tertentu, *time stretching* yaitu meregangkan audio tanpa mengubah *pitch*-nya, *shifting*, *volume change*, dan *reverberation*. Langkah selanjutnya setelah dilakukan *augmentasi* audio dilakukan *chunking* yaitu memotong audio menjadi beberapa potongan-potongan kecil dengan overlap. Setelah audio argumentasi dan dibagi menjadi *chunk*, fitur-fitur audio diekstraksi untuk digunakan dalam pelatihan model. Fitur ekstraksi yang digunakan yaitu dengan *mel spectrogram* dan MFCC. *Mel spectrogram* merepresentasikan representasi waktu-frekuensi serta mengubah ke dalam skala desibel, sedangkan MFCC merepresentasi lain dari audio yang mengukur energi dalam berbagai *bend* frekuensi mel. Terakhir, *mel spectrogram* dan MFCC yang telah diekstraksi akan digabungkan menjadi *array* fitur, untuk memberikan informasi yang berbeda tentang audio dan menyimpannya untuk pengolahan berikutnya. Secara matematis, *mel-spectrogram* dan MFCC dapat dilakukan dengan langkah-langkah sebagai berikut.

2.2.1 Mel-Spectrogram

Langkah-langkah yang dilakukan dalam mengekstraksi fitur dengan *mel-spectrogram* sebagai berikut.

1. **STFT (Short-Time Fourier Transform):** Memecah sinyal audio kedalam komponen waktu-frekuensi tertentu.

$$X(m, k) = \sum_n^{N-1} x(n) \cdot w(n - mR) e^{-j \frac{2\pi}{N} kn} \quad (1)$$

Dimana, $x(n)$ merupakan sinyal audio, $w(n)$ jendela (Hamming atau Hann), R yaitu jarak antar frame, N panjang FTT, m merupakan indeks frame, dan k yakni indeks frekuensi.

2. **Konversi skala mel:** Spektrum frekuensi hasil dari STFT dikonversi ke dalam skala mel menggunakan *mel-bank*.

$$f_{Mel} = 2595 \log_{10} \left(1 + \frac{f}{700} \right) \quad (2)$$

3. **Magnitude *mel-spectrogram*** hasil skala mel selanjutnya dihitung untuk menghasilkan nilai magnitude.

$$Mel\ Spectrogram(m, k) = |Filter\ Mel - bank|X(m, k)|^2 \quad (3)$$

2.2.2 MFCC (Mel Frequency Cepstral Coefficients)

Selanjutnya hasil dari perolehan *mel-spectrogram* dilanjutkan pada tahapan MFCC dengan Langkah sistematis sebagai berikut.

1. **Mel-Spectrogram:** Gunakan hasil dari hasil *mel-spectrogram* dari langkah sebelumnya yang telah diperoleh.
2. **Logarithm Power Spectrum:** Terapkan logaritma pada nilai *Mel-Spectrogram* dengan menyamakan persepsi suara manusia.

$$LogMel(m, k) = \log (Mel\ Spectrogram(m, k)) \quad (4)$$

3. **Discrete Cosine Transform (DCT)**: Diterapkan untuk menghasilkan koefisien MFCC.

$$MFCC(c) = \sum_{k=1}^K \text{LogMel}(m, k) \cos\left(c \frac{(k - 0.5)\pi}{K}\right) \quad (5)$$

Dengan c adalah indeks MFCC dan K merupakan jumlah filter mel.

4. **Cepstral Lifting (Optional)**: meningkatkan kontribusi koefisien tertentu.


$$MFCC_{Lifted}(c) = mfcc(c) \left(1 + \frac{L}{2} \sin\left(\frac{\pi c}{L}\right)\right) \quad (6)$$

Dimana L adalah filter parameter.

Proses ini mengonversi sinyal waktu ke representasi waktu-frekuensi (*spectrogram*) yang mempermudah analisis oleh model. Ekstraksi fitur dari spectrogram ini menjadi input untuk melatih model mendeteksi suara kepaan sayap nyamuk. Hasil ekstraksi fitur ini disimpan secara berurutan dan digunakan untuk melatih model pembelajaran mesin (Carvalho et al., 2023).

2.3 Model CNN (Convolutional Neural Network)

Model Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini dirancang dengan beberapa *hyperparameter* penting untuk mengoptimalkan performa dalam klasifikasi suara nyamuk. Arsitektur model terdiri dari lima blok konvolusi berturut-turut dengan jumlah filter yang meningkat secara bertahap, yakni: 32, 64, 128, 256, dan 512 filter. Setiap layer konvolusi menggunakan ukuran kernel sebesar 33 dengan fungsi aktivasi ReLU untuk memperkenalkan non-linearitas dan memungkinkan model mempelajari fitur kompleks dari data audio. Selain itu, diterapkan regularisasi L2 dengan koefisien 0.01 pada setiap layer konvolusi guna mengurangi overfitting. Proses downsampling dilakukan melalui lapisan *MaxPooling* dengan ukuran *pool* 2x2 di setiap blok konvolusi. Arsitektur lengkap model dapat dilihat pada Tabel 2 dan Gambar 2.



Gambar 2. Arsitektur Model CNN dalam Mengklasifikasikan Suara Kepakan Nyamuk

Tabel 2. Parameter dan Arsitektur CNN

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 180, 180, 32)	608
conv2d_1 (Conv2D)	(None, 178, 178, 32)	9,248
max_pooling2d (MaxPooling2D)	(None, 89, 89, 32)	0
conv2d_2 (Conv2D)	(None, 89, 89, 64)	18,496
conv2d_3 (Conv2D)	(None, 87, 87, 64)	36,928
max_pooling2d_1 (MaxPooling2D)	(None, 43, 43, 64)	0
conv2d_4 (Conv2D)	(None, 43, 43, 128)	73,856
conv2d_5 (Conv2D)	(None, 41, 41, 128)	147,584
max_pooling2d_2 (MaxPooling2D)	(None, 20, 20, 128)	0
conv2d_6 (Conv2D)	(None, 20, 20, 256)	295,168
conv2d_7 (Conv2D)	(None, 18, 18, 256)	590,08
max_pooling2d_3 (MaxPooling2D)	(None, 9, 9, 256)	0
conv2d_8 (Conv2D)	(None, 9, 9, 512)	1,180,160
conv2d_9 (Conv2D)	(None, 7, 7, 512)	2,359,808
max_pooling2d_4 (MaxPooling2D)	(None, 3, 3, 512)	0
flatten (Flatten)	(None, 4608)	0
dropout (Dropout)	(None, 20, 20, 128)	0
dropout_1 (Dropout)	(None, 3, 3, 512)	0
dense (Dense)	(None, 1200)	5,530,800
dropout_2 (Dropout)	(None, 1200)	0
dense_1 (Dense)	(None, 3)	3,603

Pelatihan dilakukan dengan iterasi sebanyak 100 *epoch*, dengan ukuran *batch* sebesar 32. Mekanisme penghentian dini diterapkan untuk mengakhiri pelatihan apabila tidak terjadi peningkatan selama 5 *epoch* berturut-turut. Untuk mencegah *overfitting* lebih lanjut, *dropout* dengan tingkat 0.3 diterapkan setelah blok konvolusi ketiga dan kelima, serta tingkat 0.45 sebelum *fully connected layer*. Model juga memiliki satu *fully connected layer* dengan 1.200 neuron untuk menggabungkan fitur-fitur yang telah diekstraksi. Lapisan output menggunakan fungsi aktivasi softmax dengan tiga neuron, sesuai dengan jumlah kelas nyamuk yang diklasifikasikan, yaitu *Aedes aegypti*, *Anopheles stephensi*, dan *Culex pipiens*.

2.4 Evaluasi Model

Evaluasi model machine learning sangat penting untuk menjamin kualitas dan kinerja model CNN yang dihasilkan (Raschka, 2018). Pada studi ini, model CNN yang digunakan untuk mengklasifikasi suara nyamuk dievaluasi menggunakan metrik utama, yakni: akurasi, presisi, recall, dan F1-skor (Durier et al., 2019). Pemilihan metrik ini memungkinkan analisis menyeluruh terhadap kinerja model dalam membedakan tiga spesies nyamuk yang diteliti (*Aedes aegypti*, *Anopheles stephensi*, dan *Culex pipiens*). Selain itu, evaluasi model juga dilengkapi dengan analisis menggunakan *confusion matrix* untuk mengidentifikasi distribusi kesalahan klasifikasi antar kelas, sebagaimana tersaji pada Gambar 3 (Durier et al., 2019).

CM (P.Class=A)		Estimate			Metrics
		A	B	C	
Predic ted	A	TP	FN	FN	Sensitivity
	B	FP	TN	TN	Specificity
	C	FP	TN	TN	

Gambar 3. Confusion Matriks Untuk Klasifikasi 3 Kelas Nyamuk

Akurasi adalah ukuran yang menunjukkan seberapa tepat suatu model prediksi dalam memprediksi kejadian yang benar.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

Dimana, TP adalah Suara nyamuk yang benar di prediksi diklasifikasikan sesuai dengan spesies aslinya, TN adalah Suara nyamuk yang benar tidak diklasifikasikan sebagai spesies lain, TP adalah Suara nyamuk yang salah diklasifikasikan sebagai spesies tertentu, dan FN adalah suara nyamuk yang salah tidak diklasifikasikan sebagai spesies yang seharusnya.

Presisi mengukur seberapa akurat model dalam memprediksi kelas tertentu dari semua prediksi positif yang dibuat.

$$Presisi = \frac{TP}{TP + FP} \quad (8)$$

Recall (Sensitivitas) mengukur kemampuan model dalam mengidentifikasi dengan tepat seluruh sampel yang termasuk dalam kelas positif.

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

F1-score adalah pengukuran dengan menggabungkan presisi dan *recall*, sehingga memberikan keseimbangan antara keduanya.


$$F1Score = \frac{2(Presisi \times Recall)}{Presisi + Recall} \quad (11)$$

Hasil dari evaluasi matrik ini akan menunjukkan efektivitas model CNN yang telah dikembangkan, apakah telah memenuhi standar kinerja atau masih membutuhkan penyempurnaan.


3 HASIL DAN PEMBAHASAN

Arsitektur model *Convolution Neural Network* (CNN) dirancang dengan mengkonfigurasi berbagai parameter yang digunakan. Parameter tersebut mencakup 10 lapisan konvolusi (Conv2D) sebagai lapisan utama, diikuti oleh 5 lapisan *MaxPooling2D*, lapisan *flatten*, lapisan *dense*, dan lapisan *dropout*. Untuk fungsi aktivasi, model ini menggunakan *Rectified Linear Unit* (ReLU) dan *softmax*. Detail spesifik mengenai parameter-parameter yang digunakan dapat dilihat pada Tabel 2.

Hasil yang diperoleh dari grafik pada Gambar 4 dan Gambar 5 menunjukkan perkembangan nilai *loss* untuk data pelatihan dan data validasi yang dilakukan selama 100 *epoch*. Berdasarkan pengujian nilai iterasi didapatkan nilai akurasi akhir pada data pelatihan sebesar 0.9787 dan nilai *loss* sebesar 0.5083. Sedangkan, nilai akurasi pada data validasi sebesar 0.9606 dan nilai *loss* yang dihasilkan sebesar 0.5244. Berdasarkan grafik *training* dan *validation loss*, model menunjukkan proses pelatihan yang stabil dengan nilai *loss* yang terus menurun hingga mencapai titik konvergensi. Hal ini didukung oleh grafik *training* dan *validation accuracy* yang menunjukkan bahwa akurasi model meningkat secara signifikan pada awal pelatihan dan stabil mendekati 98% sehingga model memiliki kemampuan generalisasi yang baik pada data pelatihan dan data validasi.



Gambar 4. *Training and Validation Loss*




Gambar 5. *Training and Validation Accuracy*

Pada Tabel 3. menunjukkan bahwa model ini berhasil mencapai nilai presisi, *recall*, dan *F1-score* yang sangat tinggi pada ketiga kelas spesies. *Aedes Aegypti* memiliki nilai presisi tertinggi 0.99, sedangkan *Anopheles Stephensi* dan *Culex Pipiens* mencapai nilai presisi dan *recall* sebesar 0.98. Nilai *F1-score* yang konsisten di kisaran 0.98 - 0.99 menunjukkan keseimbangan yang baik antara kemampuan model mendeteksi dan mengklasifikasikan nyamuk dengan benar. Akurasi keseluruhan sebesar 98%, yang didukung oleh nilai *Macro Average* dan *Weighted Average* sebesar

0.98 pada semua matrik evaluasi. Hal ini menegaskan bahwa mencerminkan kinerja model stabil dan seragam di seluruh kelas.

Tabel 3. Evaluasi Performa Model CNN

	Precision	Recall	F1-Score	Support
<i>Aedes Aegypti</i>	0.99	0.99	0.99	132
<i>Anopheles S.p</i>	0.98	0.98	0.98	122
<i>Culex P.p</i>	0.98	0.98	0.98	127
Accuracy			0.98	381
Macro Avg	0.98	0.98	0.98	381
Weighted Avg	0.98	0.98	0.98	381



Gambar 6. Hasil Klasifikasi dengan *Confusion Matrix*

Berdasarkan Gambar 6 hasil menunjukkan bahwa performa model dapat dievaluasi dari jumlah prediksi benar dan salah pada setiap kelas nyamuk. Confusion Matrix yang dihasilkan pada penelitian ini terdiri dari tiga kelas nyamuk : *Aedes aegypti*, *Anopheles stephensi*, dan *Culex pipiens*. Kelas *Aedes aegypti*, model berhasil mengklasifikasikan 131 sampel dengan benar sebagai *Aedes aegypti* (*True Positive*), sementara hanya terdapat satu sampel yang salah diklasifikasikan sebagai *Culex pipiens*. Tidak ada kesalahan klasifikasi ke kelas *Anopheles stephensi* yang menunjukkan bahwa model memiliki akurasi tinggi dalam mengenali nyamuk dari kelas ini.

Kelas *Anopheles stephensi*, sebanyak 120 sampel berhasil diklasifikasikan dengan benar, tetapi terdapat dua sampel yang salah diklasifikasikan sebagai *Culex pipiens*. Tidak ada sampel dari kelas ini yang salah diklasifikasikan sebagai *Aedes aegypti* . Meskipun akurasi cukup tinggi, kesalahan kecil ini menunjukkan adanya kemiripan karakteristik suara kepakan sayap dengan kelas lain, khususnya pada kelas *Culex pipiens*. Kelas *Culex pipiens*, model mengklasifikasikan 124 sampel dengan benar, tetapi terdapat satu kesalahan klasifikasi ke dalam kelas *Aedes aegypti* dan dua kesalahan ke kelas *Anopheles stephensi*. walaupun akurasi keseluruhan masih cukup baik, adanya

kesalahan ini bisa saja disebabkan oleh *overlap* fitur suara antara kelas *Culex pipiens* dengan dua kelas lainnya.

4 KESIMPULAN

Penelitian ini berhasil mengembangkan model *Convolutional Neural Network* (CNN) untuk klasifikasi suara nyamuk, yang mampu mendeteksi tiga spesies utama vektor penyakit di Indonesia: *Aedes aegypti*, *Anopheles stephensi*, dan *Culex pipiens* dengan akurasi mencapai 98%. Fitur *Mel-Frequency Cepstral Coefficients* (MFCC) dan *Mel-Spectrogram* efektif dalam ekstraksi audio, memungkinkan deteksi yang akurat meski di lingkungan bising. Hasil evaluasi menunjukkan performa model yang seimbang dengan *F1-score* sekitar 0.98 pada ketiga spesies. Teknologi ini berpotensi mempercepat deteksi nyamuk, mendukung program pengendalian penyakit, dan meningkatkan kesadaran masyarakat terhadap kebersihan lingkungan. Untuk meningkatkan efektivitas model ini, disarankan agar dilakukan pengujian lebih lanjut di berbagai kondisi lingkungan yang berbeda, serta melibatkan lebih banyak variasi spesies dan rekaman suara nyamuk dari berbagai daerah di Indonesia. Selain itu, kolaborasi dengan pihak kesehatan masyarakat dan lingkungan dapat membantu dalam implementasi teknologi ini secara luas, sehingga mendukung upaya pengendalian penyakit secara berkelanjutan. Secara keseluruhan, model ini dapat berkontribusi pada eliminasi malaria dan filariasis pada 2030 serta penurunan insiden DBD di Indonesia.

UCAPAN TERIMA KASIH

Alhamdulillahirabbil Alamin, Puji dan syukur Kami panjatkan kepada Tuhan Yang Maha Esa, karena atas berkat dan rahmat-Nya, kami dapat menyelesaikan penelitian dengan judul “Klasifikasi Suara Nyamuk Berbasis CNN (*Convolutional Neural Network*) untuk Inovasi Pengendalian Hama dan Penyakit”. Penelitian ini didasari adanya urgensi di Indonesia dalam rangka mengurangi permasalahan penyakit yang disebabkan oleh nyamuk. Kami mengucapkan terima kasih kepada bapak Christyan Tamaro Nadeak, M.Si., bapak Ardika Satria, M.Si., dan ibu Ade Lailani, M.Si., yang telah membimbing dan memberikan arahan selama proses penelitian ini.

DAFTAR PUSTAKA

- Carvalho, S., & Gomes, E. F. (2023). Automatic Classification of Bird Sounds: Using MFCC and Mel Spectrogram Features with Deep Learning. *Vietnam Journal of Computer Science*, 39–54.
- Durier, F., & Garcia, A. C. (2019). Judice Verum a Methodology for Automatically Classify Fake, Sarcastic and True Portuguese News.
- Fernandes, M. S., Cordeiro, W., & Recamonde-Mendoza, M. (2021). Detecting *Aedes aegypti* mosquitoes through audio classification with convolutional neural networks. *Computers in Biology and Medicine*.
- Jaehoon, K., Jeongkyu, O., & Tae-Young, H. (2021). Acoustic Classification of Mosquitoes using. *IJIMAI JOURNAL*.
- Kemkes. (2021, November 30). *Upaya Pengendalian Nyamuk di 1.000 Titik Wilayah*. Retrieved from kemkes.go.id: <https://kemkes.go.id/id/rilis-kesehatan/upaya-pengendalian-nyamuk-di-1-000-titik-wilayah>
- Motta, D., Santos, A. Á., Santos, A. Á., & Winkler, I. (2019). Application of convolutional neural networks for classification of adult mosquitoes in the field. *journal pone*.

- Mukundarajan, H., Hol, F. J., Erica Araceli Castillo, C. N., & Prakash, M. (2018). Data from: Using mobile phones as acoustic sensors for high-throughput mosquito surveillance. Retrieved from <https://doi.org/10.5061/dryad.98d7s>
- Permana, S. D., & Rahman, T. A. (2023). Improved Feature Extraction for Sound Recognition Using Combined Constant-Q Transform (CQT) and Mel Spectrogram for CNN Input. *International Conference on Modeling & E-Information Research, Artificial Learning and Digital Applications (ICMERALDA)*, 185-190.
- Pratiwi, d. A. (2024, September 27). *Perilaku Vektor Malaria di Indonesia*. Retrieved from ayosehat.kemkes.go.id: <https://ayosehat.kemkes.go.id/perilaku-vektor-malaria-di-indonesia>
- Raschka, S. (2018). *Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning*. Retrieved from <https://doi.org/10.48550/arXiv.1811.12808>
- Yohannes, & Wijaya, R. (2021). Klasifikasi Makna Tangisan Bayi Menggunakan CNN Berdasarkan Kombinasi Fitur MFCC dan DWT. *HATISI (Jurnal Teknik Informatika dan Sistem Informasi)*.