

Klasifikasi Spesies Nyamuk Berbasis Few-Shot Learning Prototypical Network dengan ResNet-34 untuk Mendukung Sistem Pengendalian Vektor

I Gde Eka Dirgayussa^{*1}, Yohanssen Pratama², Ni Wayan Puspa Apriana Susanti³, Budi Santoso⁴

¹Program Studi Teknik Biomedis, Institut Teknologi Sumatera, Lampung, 35365, Indonesia

²Nara Institute of Science and Technology, Nara, Ikoma, Takayamacho, 8916, Jepang

³Program Studi Teknik Lingkungan, Fakultas Teknik, Universitas Lampung, 35145, Indonesia

⁴Dinas Kesehatan Provinsi Lampung, Bandar Lampung 35128, Indonesia

Email: ¹i.dirgayussa@bm.itera.ac.id, ²yohanssen.pratama.yl0@is.naist.jp,

³puspadirgayussa@staff.unila.ac.id, ⁴santosobudivektor@gmail.com

Abstrak

Klasifikasi spesies nyamuk secara cepat dan akurat merupakan aspek penting dalam upaya pengendalian berbagai penyakit seperti demam berdarah, chikungunya, dan filariasis. Metode klasifikasi berbasis pembelajaran mesin konvensional umumnya membutuhkan dataset berukuran besar yang relatif sulit untuk didapatkan. Untuk mengatasi kendala tersebut, penelitian ini mengusulkan pendekatan *Few-Shot Learning* (FSL) dengan menggunakan arsitektur *Prototypical Network* yang didukung oleh *deep visual embeddings* berbasis *backbone ResNet-34*. Model dilatih secara episodik dengan sedikit data per kelas menggunakan citra dari tiga spesies nyamuk utama yaitu *Aedes aegypti*, *Aedes albopictus*, dan *Culex quinquefasciatus*. Evaluasi kinerja model dilakukan dengan menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian ini menunjukkan bahwa model dapat mencapai akurasi rata-rata sebesar 96,33% dengan deviasi antar-fold yang rendah serta stabilitas dan kemampuan generalisasi yang tinggi. Selain akurat, model ini juga efisien secara komputasi dengan waktu pelatihan rata-rata sebesar 0,83 detik per episode. Visualisasi menggunakan Grad-CAM menunjukkan bahwa model secara konsisten dapat memfokuskan perhatian pada area morfologis penting seperti *toraks* dan *abdomen* sehingga meningkatkan interpretabilitas dari proses klasifikasi. Secara keseluruhan, penelitian ini memberikan kontribusi penting dalam pengembangan sistem surveilans vektor berbasis kecerdasan buatan di wilayah dengan keterbatasan data dan sumber daya.

Kata kunci: *Few-Shot Learning*, *Grad-CAM*, *Klasifikasi Spesies Nyamuk*, *Prototypical Network*, *ResNet-34*.

Mosquito Species Identification Using Few-Shot Learning Based on Prototypical Networks and Deep Visual Embeddings

Abstract

Rapid and accurate classification of mosquito species is an important aspect in efforts to control various diseases such as dengue fever, chikungunya, and filariasis. Conventional machine learning-based classification methods generally require large datasets that are relatively difficult to obtain. To overcome these constraints, this study proposes a *Few-Shot Learning* (FSL) approach using the *Prototypical Network* architecture supported by deep visual embeddings based on the *ResNet-34* backbone. The model was trained episodically with little data per class using imagery from three main mosquito species: *Aedes aegypti*, *Aedes albopictus*, and *Culex quinquefasciatus*. Evaluation of model performance is carried out using accuracy, precision, recall, and F1-score metrics. The results showed that the model achieved an average accuracy of 96.33% with low inter-fold deviation and high stability and generalization ability. In addition to being accurate, this model is also computationally efficient with an average training time of 0.83 seconds per episode. Visualizations using Grad-CAM show that the model can consistently focus attention on important morphological areas such as the thorax and abdomen, thus increasing the interpretability of the classification process. Overall, this study provides an important contribution to the development of AI-based vector surveillance systems in regions with limited data and resources.

Keywords: *Few-Shot Learning*, *Grad-CAM*, *Mosquito Species Classification*, *Prototypical Network*, *ResNet-34*.

1. PENDAHULUAN

Nyamuk merupakan vektor utama berbagai penyakit tropis yang berdampak signifikan terhadap kesehatan masyarakat, khususnya bagi negara-negara yang memiliki iklim tropis dan subtropis. Tiga spesies nyamuk yang paling berperan dalam penularan penyakit tropis adalah *Aedes aegypti*[1], *Aedes albopictus*[2], dan *Culex quinquefasciatus*[3]. Nyamuk *Aedes aegypti* dan *Aedes albopictus* dikenal sebagai vektor utama penyakit demam berdarah dengue, chikungunya, dan virus Zika[4], sedangkan *Culex quinquefasciatus* merupakan vektor utama filariasis limfatik[5]. Ketiga spesies nyamuk ini memiliki perbedaan morfologis dan perilaku yang khas seperti waktu aktif (diurnal vs. nokturnal), habitat perkembangbiakan, dan habitat lingkungan [6]. Variasi ini mengakibatkan identifikasi spesies nyamuk secara akurat menjadi sangat penting. Saat ini, identifikasi spesies nyamuk secara tradisional masih mengandalkan pendekatan morfologis yang menggunakan kunci taksonomi serta memerlukan kondisi spesimen yang utuh[7].

Keberhasilan strategi pengendalian dan eliminasi penyakit vektor sangat bergantung pada sistem pemantauan populasi nyamuk yang akurat. Identifikasi spesies merupakan langkah awal yang krusial untuk memahami dinamika penyebaran penyakit dan mengevaluasi efektivitas intervensi berbasis wilayah. Namun, metode identifikasi konvensional memiliki sejumlah keterbatasan, di antaranya proses manual yang memakan waktu, ketergantungan pada tenaga ahli, serta potensi kesalahan akibat bias subjektif. Di wilayah dengan sumber daya terbatas, ketersediaan tenaga entomolog dan fasilitas laboratorium menjadi tantangan tersendiri, menyebabkan proses identifikasi menjadi lambat dan sulit diskalakan. Oleh karena itu, dibutuhkan sistem identifikasi otomatis yang efisien, akurat, dan dapat dioperasikan oleh non-ahli di lapangan.


Beberapa penelitian terkini telah menunjukkan efektivitas *deep learning* untuk identifikasi spesies nyamuk dari citra tubuh dan sayap. Misalnya, studi *Robust Mosquito Species Identification from Diverse Body and Wing Images using Deep Learning* (2024) menggunakan CNN konvensional untuk membedakan beberapa spesies *Aedes*, dengan akurasi tinggi namun membutuhkan dataset besar dan kondisi pencitraan terkontrol[8]. Penelitian lain di Korea melibatkan 11 spesies nyamuk menggunakan kombinasi citra warna dan fluoresensi, menghasilkan nilai F1-score sekitar 97,1% [9]. Selain itu, pendekatan berbasis *Vision Transformers* juga telah dieksplorasi untuk klasifikasi terbuka (*open-set learning*) dengan performa hampir sempurna (~99,8%) pada citra laboratorium beresolusi tinggi[10]. Walaupun demikian, sebagian besar studi tersebut memiliki keterbatasan pada kebutuhan data pelatihan yang besar, hanya berfokus pada klasifikasi biner, atau belum mempertimbangkan kondisi lapangan seperti citra resolusi rendah dan variasi posisi tubuh (“landing” vs. “smashed”) yang umum terjadi dalam surveilans entomologi.

Untuk mengatasi permasalahan utama berupa keterbatasan jumlah data pelatihan dalam proses identifikasi, penelitian ini mengusulkan pendekatan berbasis *Few-Shot Learning* (FSL)[11] dengan menggunakan arsitektur *Prototypical Network*[12]. Klasifikasi dilakukan pada tiga kelas spesies dan status perilaku nyamuk dari citra beresolusi rendah. Metode ini dirancang untuk dapat melakukan klasifikasi citra walaupun hanya menggunakan sejumlah kecil contoh citra pelatihan yang terdapat di tiap kelasnya. Oleh karena itu, metode ini sangat relevan untuk diterapkan dalam konteks epidemiologi lapangan yang seringkali dihadapkan pada keterbatasan data. Berbeda dari penelitian sebelumnya yang umumnya terbatas pada klasifikasi biner atau identifikasi taksonomi secara umum[13], [14], penelitian ini secara spesifik menangkap kombinasi spesies nyamuk *Aedes aegypti*, *Aedes albopictus*, dan *Culex quinquefasciatus* serta status perilaku dalam posisi *landing* dan *smashed*. Penelitian ini berfokus pada pengenalan spesies nyamuk dari citra yang mencerminkan kondisi nyata dalam surveilans entomologi. Kontribusi utama dari penelitian ini adalah penerapan strategi *meta-learning* berbasis FSL yang sebelumnya telah terbukti efektif dalam domain pengenalan citra medis[15], [16], [17]. Strategi ini kemudian diperluas penerapannya ke ranah entomologi digital yang relatif masih jarang dieksplorasi. Evaluasi performa model dilakukan dengan menggunakan perhitungan akurasi, presisi, F1-score, analisis *confusion matrix* serta visualisasi *embedding* menggunakan t-SNE. Secara keseluruhan, hasil temuan penelitian ini memberikan kontribusi terhadap pemanfaatan kecerdasan buatan untuk klasifikasi citra biologis pada kondisi sumber daya terbatas. Selain itu, hal ini akan memperkuat integrasi teknologi digital dalam strategi eliminasi malaria dan penanggulangan penyakit tropis berbasis vektor. Tujuan penelitian ini adalah mengembangkan model *Few-Shot Learning* berbasis *Prototypical Network* dengan ResNet-34 untuk mengklasifikasikan tiga spesies nyamuk utama serta status perilaku “landing” dan “smashed” secara efisien dan akurat meskipun dengan jumlah data pelatihan yang terbatas.

2. METODE PENELITIAN

Pada bagian ini dijabarkan langkah-langkah metodologis yang diterapkan untuk mencapai tujuan penelitian, yaitu membangun model *Few-Shot Learning* yang mampu mengklasifikasi tiga spesies nyamuk utama dengan jumlah data terbatas. Prosedur penelitian meliputi tahapan pengolahan data citra, pembentukan episode pelatihan,


implementasi *Prototypical Network*, dan evaluasi performa model terhadap data uji yang ditampilkan pada Gambar 1.



Gambar 1. Metodologi penelitian

2.1. Dataset

Penelitian ini menggunakan dataset publik yang dikembangkan oleh Ong Song Quan[18] untuk klasifikasi nyamuk berbasis pengenalan citra. Dataset ini terdiri atas 1.747 citra yang telah dianotasi secara manual. Namun dalam penelitian ini, hanya digunakan sebanyak 300 citra untuk digunakan pada pelatihan model FSL. Semua citra dikumpulkan dari laboratorium pemeliharaan nyamuk yang telah diakreditasi oleh World Health Organization (WHO), sehingga menjamin standar mutu dan validitas proses anotasi yang tinggi. Dataset ini mencakup tiga spesies nyamuk yang menjadi vektor utama penyakit tropis, yaitu *Aedes aegypti*, *Aedes albopictus*, dan *Culex quinquefasciatus*. Setiap spesies nyamuk masing-masing didokumentasikan dalam dua kondisi perilaku yaitu saat nyamuk mendarat secara alami (*landing*) dan dalam kondisi setelah ditepuk (*smashed*). Kombinasi ini menghasilkan enam kelas unik yang sangat penting untuk studi pengenalan pola visual berbasis perilaku. Gambar 2 menyajikan contoh representatif dari citra nyamuk yang diambil di atas permukaan kulit manusia, dengan variasi dalam orientasi tubuh, posisi anggota tubuh, serta pencahayaan. Keragaman ini memperkaya informasi visual yang terdapat pada citra sehingga meningkatkan kompleksitas dalam proses ekstraksi fitur dan klasifikasi. Jenis citra seperti ini sangat sesuai dengan model pembelajaran FSL yang menuntut kemampuan generalisasi tinggi meskipun jumlah contoh sangat terbatas. Dataset ini tersedia secara terbuka melalui platform Mendeley Data[18], sehingga dapat digunakan secara luas dalam riset lanjutan.



Gambar 2. Contoh citra nyamuk dari dataset FSL yang digunakan dalam penelitian, mencakup tiga spesies dan dua kondisi: (a)–(b) *Culex quinquefasciatus*, (c)–(d) *Aedes albopictus*, (e)–(f) *Aedes aegypti*, masing-masing dalam kondisi *smashed* dan *landing*.

Data citra ini kemudian disusun dalam struktur direktori yang disesuaikan untuk konfigurasi pelatihan FSL berupa pemisahan data ke dalam set dukungan (*support set*) dan set pengujian (*query set*). Pengorganisasian ulang dataset ini bertujuan untuk memfasilitasi pembelajaran berbasis episode dan mereplikasi proses belajar model FSL dalam kondisi data terbatas.

2.2. Pra-pemrosesan Data dan Teknik Augmentasi

Sebelum digunakan dalam proses pelatihan, seluruh citra terlebih dahulu dilakukan *resize* ulang dalam resolusi 224×224 piksel. Hal ini dilakukan untuk memastikan keseragaman input sesuai dengan kebutuhan arsitektur ResNet-34. Selain itu, normalisasi juga diterapkan menggunakan nilai mean dan standar deviasi standar dari ImageNet yaitu ([0.485, 0.456, 0.406]; [0.229, 0.224, 0.225]). Tujuannya adalah untuk menstabilkan distribusi fitur dan mempercepat konvergensi pelatihan. Untuk meningkatkan kemampuan generalisasi model dalam kondisi jumlah data terbatas, diterapkan berbagai teknik augmentasi citra secara sistematis. Augmentasi ini mencakup rotasi acak hingga ± 20 derajat, flip horizontal acak, serta penyesuaian *brightness* dan *contrast*. Seluruh transformasi diimplementasikan secara online menggunakan *torchvision.transforms*, sehingga setiap sampel data yang digunakan dalam training episode mengalami variasi yang dinamis. Strategi ini bertujuan untuk memperkaya distribusi visual dan mengurangi risiko *overfitting*. Selain itu, proses ini akan menyebabkan model dapat belajar melalui representasi fitur yang lebih *robust* terhadap variasi pose, orientasi, dan pencahayaan.

2.3. Konfigurasi Few Shot Learning

Penelitian ini mengadopsi pendekatan *episodic training* dalam kerangka kerja FSL dengan menggunakan skema 6-way 5-shot 5-query. Dalam setiap episode pelatihan, enam kelas dipilih secara acak dari kumpulan kelas yang tersedia. Pada masing-masing kelas yang terpilih, sebanyak lima citra akan digunakan sebagai *support set* (contoh pembelajaran), dan lima citra lainnya sebagai *query set* (contoh pengujian). Konfigurasi ini dirancang untuk meniru kondisi klasifikasi dalam dunia nyata, di mana sistem hanya memiliki akses terhadap sedikit contoh dari kelas-kelas baru yang belum pernah dilihat sebelumnya. Setiap episode menghasilkan satu tugas klasifikasi tersendiri dengan distribusi label terbatas, dan proses pelatihan berlangsung selama 100 episode per *fold* dalam skema 5-fold cross-validation. Dengan menggunakan skema ini, model akan belajar membentuk representasi generalis yang mampu mengidentifikasi kelas baru hanya dari beberapa contoh. Optimisasi dilakukan menggunakan algoritma Adam dengan laju pembelajaran sebesar $1e-4$. Pada setiap episode, model melakukan ekstraksi *embedding* dari *support* dan *query set* menggunakan encoder (ResNet-34 tanpa classifier) untuk menghitung prototipe tiap kelas serta mengukur jarak Euclidean antara *query* dan *prototipe*. Nilai jarak ini dikonversi menjadi skor prediksi dan dioptimasi menggunakan fungsi kehilangan *cross-entropy*. Seluruh parameter encoder diperbarui pada setiap episode, sehingga model mampu mempelajari representasi fitur yang *transferable* dan *diskriminatif* terhadap kelas-kelas baru.

Tabel 1. Pseudocode skema FSL yang digunakan dalam penelitian ini

Input:

Dataset support $\mathcal{D} = \{(\mathbf{x}^n, \mathbf{y}^n)\}_{n=1}^N$, dengan $N = n\text{-way} \times k\text{-shot}$

Dataset query $\mathcal{Q} = \{(\mathbf{x}^m, \mathbf{y}^m)\}_{m=1}^M$

Iterasi maksimum T

Jaringan embedding f_ϕ

1. Inisialisasi Parameter ϕ

2. untuk $t = 1$ hingga T lakukan

3. Acak dataset $\mathcal{D}$

4. Ambil sampel n kelas dengan k data support dan q data query per kelas

5. Bentuk support set:

$$\mathbf{X}^s = \{\mathbf{x}_i^s\}_{i=1}^{nk}, \quad \mathbf{Y}^s = \{\mathbf{y}_i^s\}_{i=1}^{nk}$$

6. Bentuk query set:

$$\mathbf{X}^q = \{\mathbf{x}_j^q\}_{j=1}^{nq}, \quad \mathbf{Y}^q = \{\mathbf{y}_j^q\}_{j=1}^{nq}$$

7. Hitung embedding:

$$\mathbf{Z}^s = f_\phi(\mathbf{X}^s), \quad \mathbf{Z}^q = f_\phi(\mathbf{X}^q)$$

8. Hitung prototype untuk setiap kelas c :

$$\mathbf{p}_c = \frac{1}{k} \sum_{i=1}^k f_\phi(\mathbf{x}_i^s), \quad \text{dengan } \mathbf{y}_i^s = c$$

9. Hitung jarak ke prototype:

-
10. Hitung prediksi softmax:

$$\mathbf{d}_{j,c} = \| \mathbf{f}_{\phi}(\mathbf{x}_j^q) - \mathbf{p}_c \|^2$$
 11. Hitung loss cross-entropy:


$$\hat{\mathbf{y}}_j = \text{softmax}(-\mathbf{d}_{j,:})$$

$$\mathcal{L} = - \sum_{j=1}^{nq} \log \hat{\mathbf{y}}_{j,y_j^q}$$
 12. Perbaharui parameter ϕ dengan gradient descent:

$$\phi \leftarrow \phi - \alpha \nabla_{\phi} \mathcal{L}$$
 13. Selesai
- Output: Fungsi embedding terlatih $\mathbf{f}_{\phi}$
-

2.4. Arsitektur Prototypical Network dengan Resnet-34

Model klasifikasi yang digunakan dalam penelitian ini merupakan implementasi dari *Prototypical Network* yang berfokus pada pembelajaran representasi berbasis perhitungan jarak terdekat. Arsitektur ini menggunakan ResNet-34 sebagai *backbone feature extractor*, dengan bobot awal (*pretrained weights*) yang telah dilatih pada dataset ImageNet. Layer klasifikasi akhir dari ResNet-34 dihapus dan digantikan dengan *nn.Identity()* untuk pengambilan fitur *embedding* secara langsung dari lapisan akhir sebelum klasifikasi. *Embedding* yang dihasilkan memiliki dimensi tetap dan berfungsi sebagai representasi laten dari citra masukan.



Gambar 3. Arsitektur Prototypical Network dengan Resnet-34

Dalam setiap episode, *embedding* dari *support set* digunakan untuk menghitung vektor prototipe per kelas berupa rata-rata vektor *embedding* dari semua contoh *support* dalam satu kelas. Kemudian, *embedding* dari *query set* dibandingkan dengan prototipe di semua kelas menggunakan jarak Euclidean. Hasil skor prediksi kemudian diberikan berdasarkan perhitungan kelas dengan jarak terkecil dari prototipe yang dianggap sebagai prediksi model. Perhitungan seperti ini akan memberikan fungsi klasifikasi yang fleksibel dan efisien terhadap kelas-kelas baru tanpa perlu dilakukan training secara berulang. Proses ini dapat dilakukan karena proses inferensi cukup bergantung pada perhitungan kedekatan antara *embedding* terhadap prototipe.

2.5. Protokol Evaluasi

Evaluasi model dilakukan dengan menggunakan pendekatan berbasis episode yang dibagi ke dalam beberapa *fold* pelatihan. Pada setiap *fold* pelatihan, dilakukan evaluasi independen sebanyak 10 episode dengan menggunakan skema klasifikasi 6-way, 5-shot, dan 5-query. Hasil prediksi dari seluruh episode dan seluruh *fold* kemudian digabungkan secara agregat untuk memperoleh metrik evaluasi. Beberapa metrik digunakan untuk mengukur performa model secara komprehensif. Metrik utama yang digunakan adalah perhitungan akurasi yang dihitung sebagai rasio antara jumlah prediksi query yang benar terhadap total jumlah query di seluruh episode. Selain itu, juga dihitung *precision*, *recall* (sensitivitas), dan F1-score berdasarkan rumus berikut:

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

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

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

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

Dengan TP = true positive, TN = true negative, FP = false positive, dan FN = false negative. Distribusi kesalahan klasifikasi divisualisasikan melalui *confusion matrix* yang dihasilkan untuk masing-masing *fold* maupun secara keseluruhan (*cross-fold*). Untuk mengevaluasi kualitas probabilitas model, digunakan kurva ROC (*Receiver Operating Characteristic*) dan AUC (*Area Under Curve*) per kelas. Selain itu, dilakukan pula visualisasi *embedding* menggunakan *t-distributed Stochastic Neighbor Embedding* (t-SNE) untuk mengamati separabilitas antar kelas dalam ruang. Kombinasi berbagai metrik dan visualisasi ini memberikan gambaran secara menyeluruh terhadap kemampuan klasifikasi dan generalisasi model dalam skenario pelatihan dengan data terbatas. Seluruh proses pelatihan dan pengujian model dijalankan pada platform Google Colab dengan GPU NVIDIA Tesla T4 menggunakan framework PyTorch dan pustaka pendukung Scikit-learn.

3. HASIL DAN PEMBAHASAN

3.1. Kinerja Klasifikasi Model


Untuk mengevaluasi stabilitas dan kemampuan generalisasi model dalam skenario FSL, dilakukan pengujian menggunakan skema lima *fold cross validation* dengan konfigurasi pelatihan berbasis episode. Hasil evaluasi model berdasarkan metrik akurasi, presisi, *recall*, dan F1-score, serta rata-rata waktu pelatihan per episode untuk masing-masing *fold* ditunjukkan pada Tabel 2. Evaluasi ini bertujuan untuk mengukur konsistensi performa model terhadap variasi distribusi data antar *fold*.

Tabel 2. Hasil Evaluasi Model Prototypical Network per Fold

Fold	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)	Rata-rata waktu per episode (s)
1	94.00	94.21	94.00	94.01	1.56
2	99.00	99.03	99.00	99.00	0.65
3	96.67	96.79	96.67	96.67	0.65
4	97.33	97.45	97.33	97.35	0.65
5	97.33	97.40	97.33	97.34	0.64
Rata-rata	96.87	96.98	96.87	96.87	0.83
Deviasi	1.82	1.75	1.82	1.82	0.41

Hasil ini menunjukkan bahwa model Prototypical Network dengan backbone ResNet-34 menghasilkan performa klasifikasi yang sangat baik secara konsisten di seluruh *fold*. Rata-rata akurasi mencapai 96,87% dengan standar deviasi yang relatif rendah yaitu 1,82%. Nilai precision, recall, dan F1-score juga menunjukkan konsistensi yang tinggi. Hal ini mengindikasikan bahwa model tidak hanya akurat tetapi juga seimbang dalam mengidentifikasi kelas positif dan kelas negatif. *Fold* ke-2 menunjukkan performa tertinggi di seluruh metrik utama (99,00%), sedangkan *fold* ke-1 memiliki performa sedikit lebih rendah dibandingkan dengan *fold* lainnya. Hal ini dapat disebabkan oleh variasi distribusi citra dalam *fold* tersebut seperti noise, rotasi, atau perbedaan pencahayaan. Namun demikian, seluruh *fold* tetap menghasilkan performa di atas 93% yang menunjukkan bahwa tingkat generalisasi model yang baik dalam skenario data pelatihan yang terbatas. Hasil yang diperoleh menunjukkan bahwa model *Few-Shot Learning* berbasis *Prototypical Network* mampu mencapai akurasi yang lebih tinggi. Temuan ini sejalan dengan penelitian yang dilakukan oleh Ragu et al. [19] yang menunjukkan bahwa *metric-based learning* memberikan keunggulan dalam skenario dengan jumlah data terbatas.

Dari sisi efisiensi, rata-rata waktu pelatihan per episode sebesar 0,83 detik, dengan deviasi 0,41 detik. Waktu pelatihan yang relatif rendah menunjukkan bahwa model memiliki efisiensi komputasi yang sangat baik selama proses pelatihan. Selain itu, evaluasi multi *fold* yang dilakukan juga memperkuat temuan bahwa pendekatan FSL berbasis Prototypical Network tidak hanya memiliki tingkat akurasi yang tinggi, tetapi juga menunjukkan efisiensi dan stabilitas performa yang konsisten. Evaluasi per-episode juga menunjukkan stabilitas prediksi dengan standar deviasi akurasi antar episode relatif rendah sebesar <3%. Kurva ROC untuk enam kelas nyamuk ditunjukkan pada Gambar 4, dengan seluruh kelas mencapai AUC nilai yang tinggi sebesar 1.00. Hal ini menunjukkan bahwa kemampuan diskriminatif model yang sangat tinggi dalam memisahkan kelas positif dan negatif.




Gambar 4. Kurva ROC


Bentuk kurva ROC yang menempel pada sudut kiri atas mengindikasikan tingkat *true positive* yang tinggi dan *false positive* yang rendah. Hal ini mencerminkan efektivitas *embedding* yang dihasilkan oleh ResNet-34 dan mekanisme perhitungan jarak Euclidean dalam membentuk representasi fitur yang terpisah antar kelas. Temuan ini menegaskan bahwa model memiliki potensi yang besar untuk dapat diterapkan dalam sistem klasifikasi nyamuk otomatis secara langsung dalam kondisi nyata.

3.2. Analisis Confusion Matrix

Hasil analisis *confusion matrix* dari fold 1 sampai 5 secara berurutan ditunjukkan pada Gambar 5 (a-e) sedangkan Gambar 5 (f) merupakan *confusion matrix* agregat hasil penggabungan seluruh prediksi dari kelima *fold*. Secara umum, model menunjukkan performa klasifikasi yang sangat tinggi dan konsisten, dengan mayoritas prediksi terkonsentrasi pada diagonal utama, yang menandakan prediksi yang benar. Pada cross-fold yang ditunjukkan oleh Gambar 5 (f), terlihat bahwa model menghasilkan prediksi yang sangat akurat untuk semua kelas. Jumlah prediksi benar pada nilai diagonal mendekati nilai maksimum (246/250) dan jumlah kesalahan klasifikasi yang tersebar sangat kecil pada sel non-diagonal. Beberapa kesalahan yang muncul terutama terjadi pada kelas-kelas dengan morfologi visual yang serupa, seperti antara *Aedes aegypti* dalam posisi *smashed* (AAE_S) dan *Aedes albopictus* dalam posisi *landing* (AAL_L), atau antara *Culex quinquefasciatus* dalam posisi *smashed* (CQU_S) dan AAE_S. Meskipun demikian, proporsi kesalahan pada setiap fold masih dalam kategori sangat rendah yaitu <3%.

Confusion matrix juga menunjukkan bahwa performa model stabil di setiap *fold*, tanpa adanya degradasi signifikan pada kelas tertentu. Misalnya pada *fold* 1 dan *fold* 2, kesalahan klasifikasi hampir tidak terjadi dengan nilai F1-score yang mendekati sempurna untuk hampir semua kelas. Hanya pada *Fold* 5 ditemukan sedikit peningkatan kesalahan untuk kelas AAE_S yang terklasifikasi sebagai AAE_L dan AAL_L, kemungkinan disebabkan oleh faktor variasi intra-kelas dalam data pelatihan episode tersebut. Secara keseluruhan, hasil ini memperkuat klaim bahwa model mampu membedakan antar kelas nyamuk secara efektif khususnya dalam kondisi keterbatasan data latih seperti pada skenario *few-shot*. Kualitas klasifikasi yang konsisten antar *fold* membuktikan bahwa proses *episodic training* menghasilkan representasi fitur yang stabil, *transferable*, dan *robust* terhadap variasi distribusi antar episode.






Gambar 5. *Confusion Matrix* untuk masing-masing *fold* (a) *fold* 1, (b) *fold* 2 (b) *fold* 3 (b) *fold* 4 (b) *fold* 5 dan (f) *cross fold*

3.3. Evaluasi Performa Per Kelas

Hasil evaluasi metrik klasifikasi secara terperinci untuk masing-masing kelas ditunjukkan pada Gambar 6. Secara umum, seluruh kelas menunjukkan performa yang sangat baik dengan nilai *F1-score* berada pada rentang 0.94 hingga 0.99. Hal ini mengindikasikan bahwa model tidak hanya mampu melakukan klasifikasi yang akurat, tetapi juga konsisten dalam mengenali setiap kelas secara seimbang antara sensitivitas dan presisi. Kelas *Aedes albopictus smashed* (AAL_S) dan *Culex quinquefasciatus smashed* (CQU_S) mencapai performa tertinggi secara konsisten di ketiga metrik, menunjukkan bahwa karakteristik visual dari kelas ini cukup khas dan mudah dipisahkan oleh model. Sebaliknya, nilai *precision* sedikit menurun pada kelas *Culex quinquefasciatus landing* (CQU_L) dan *Aedes albopictus landing* (AAL_L), meskipun *recall* pada kelas tersebut tetap tinggi.




Gambar 6. Evaluasi klasifikasi per kelas menggunakan metrik *precision*, *recall*, dan *F1-score*. Model menunjukkan performa tinggi dan seimbang di seluruh kelas, dengan nilai *F1-score* di atas 0.94

Hal ini menunjukkan bahwa model sesekali melakukan kesalahan prediksi positif terhadap kelas lain dengan pola visual yang mirip, namun tetap berhasil mendeteksi sebagian besar sampel aktual dari kelas tersebut. Temuan ini mendukung hasil pada *confusion matrix* sebelumnya yang menunjukkan adanya tumpang tindih antar kelas dengan morfologi atau pose yang serupa. Secara keseluruhan, distribusi metrik per kelas yang merata memperkuat bukti bahwa model memiliki kapabilitas generalisasi yang baik dan tidak terfokus hanya pada subset kelas tertentu.

3.4. Analisis Visualisasi *Embedding* dengan t-SNE

Visualisasi *embedding* yang dihasilkan dari *Prototypical Network* menunjukkan pemisahan yang jelas antara tiga enam kelas, seperti ditunjukkan pada Gambar 7. Meskipun pendekatan pembelajaran yang digunakan bersifat *few-shot* (5 contoh per kelas), distribusi kelompok (*cluster*) telah memperlihatkan pengelompokan dengan batas yang jelas. Hal ini menandakan bahwa model mampu menangkap ciri morfologi spesifik dari masing-masing kelas spesies nyamuk. Kelas *AAE* dan *AAE_L* yang secara taksonomi memiliki kedekatan, menunjukkan variasi intra-kelas yang sedang, tercermin dari adanya sedikit tumpang tindih dalam ruang *embedding*.




Gambar 7. Evaluasi Visualisasi t-SNE pada ruang *embedding* untuk enam kelas nyamuk menggunakan Prototypical Network. Setiap titik mewakili citra nyamuk, dengan *cluster* yang mencerminkan pemisahan antar spesies berdasarkan fitur morfologi dan posisi nyamuk.

Sebaliknya, *AAE_L* membentuk cluster yang lebih rapat dan konsisten, yang mengindikasikan bahwa tingkat keyakinan klasifikasi yang lebih tinggi dari model. Visualisasi yang diperoleh melalui algoritma t-SNE pada ruang *embedding* memberikan bukti tambahan bahwa klasifikasi dalam pendekatan *few-shot* mampu menghasilkan representasi diskriminatif, bahkan dari data yang sangat terbatas. Distribusi spasial ini memperkuat efektivitas Prototypical Network dalam tugas klasifikasi gambar entomologis, khususnya pada skenario dengan jumlah data pelatihan yang terbatas.

3.5. Visualisasi *Attention Map* Model Menggunakan Grad-CAM

Untuk memahami interpretabilitas dari model klasifikasi yang digunakan, dilakukan visualisasi area yang menjadi perhatian (*attention map*) menggunakan teknik *Gradient-weighted Class Activation Mapping* (Grad-CAM). Teknik ini bertujuan untuk mengidentifikasi area pada citra input yang memiliki kontribusi paling signifikan terhadap keputusan klasifikasi model. Grad-CAM ini diterapkan pada model Prototypical Network dengan backbone ResNet-34 yang telah dilatih sebelumnya. Hasil visualisasi Grad-CAM pada beberapa sampel citra nyamuk ditunjukkan pada Gambar 8 (a-f). Peta aktivasi ditampilkan dalam bentuk overlay warna merah pada gambar asli (*original image*), di mana intensitas warna menunjukkan tingkat kontribusi terhadap prediksi model. Hasil visualisasi menunjukkan bahwa model secara konsisten memfokuskan perhatian pada bagian tubuh utama nyamuk, khususnya bagian *toraks* dan *abdomen* yang memiliki karakteristik morfologis untuk membedakan antar spesies. Hal ini menegaskan bahwa representasi spasial yang dipelajari oleh ResNet-34 bersifat relevan secara biologis dan tidak bersifat acak. Pada beberapa kasus, model juga memperhatikan bagian kaki atau sayap yang tergantung pada posisi nyamuk dalam citra. Selain itu, visualisasi Grad-CAM juga menunjukkan konsistensi area perhatian pada gambar dengan latar belakang dengan pencahayaan rendah. Hal ini mengindikasikan ketahanan model terhadap variasi kondisi lingkungan. Namun, pada beberapa kasus kesalahan klasifikasi, Grad-CAM memperlihatkan fokus perhatian yang menyebar ke area non-relevan, seperti latar belakang atau artefak pencitraan, yang dapat menjelaskan menurunnya keakuratan pada contoh tersebut.



Gambar 8. Visualisasi Grad-CAM pada beberapa sampel citra tiga spesies dan dua kondisi: (a)–(b) *Culex quinquefasciatus*, (c)–(d) *Aedes albopictus*, (e)–(f) *Aedes aegypti*, masing-masing dalam kondisi *smashed* dan *landing*. Area merah menunjukkan fokus perhatian utama dari model dalam proses klasifikasi.

Hasil Grad-CAM mengindikasikan bahwa model tidak hanya mengandalkan fitur global, tetapi mampu mengisolasi fitur morfologis penting dalam pengambilan keputusan. Temuan ini mendukung keandalan model untuk diterapkan dalam sistem klasifikasi spesies nyamuk berbasis citra untuk aplikasi klinis lebih lanjut. Selain itu, penggunaan Grad-CAM berfungsi sebagai alat validasi penting untuk mencegah bias dalam model dan memfasilitasi audit interpretatif bagi para ahli entomologi atau pengguna akhir dari sistem. Sebagai kesimpulan, model ini berpotensi digunakan oleh petugas lapangan maupun Dinas Kesehatan untuk membantu dalam identifikasi cepat spesies nyamuk vektor melalui citra dari mikroskop digital atau kamera smartphone untuk mempercepat surveilans vektor dan mendukung pengendalian penyakit malaria.

3.5. Efisiensi Komputasi

Efisiensi komputasi dievaluasi berdasarkan waktu pelatihan per episode, penggunaan memori GPU, dan kecepatan inferensi selama pengujian. Semua eksperimen dilakukan pada lingkungan komputasi dengan spesifikasi GPU NVIDIA Tesla T4 (16GB VRAM), RAM 32GB dan prosesor Intel Xeon serta menggunakan framework PyTorch versi 1.13. Untuk mengoptimalkan efisiensi, proses pelatihan menggunakan *episodic training*, di mana setiap episode terdiri dari *5-shot* dan *5-query* untuk setiap kelas. Dibandingkan metode konvensional berbasis *supervised learning* penuh, pendekatan FSL secara signifikan mengurangi kebutuhan data dan waktu pelatihan karena hanya memanfaatkan sejumlah kecil sampel per kelas. Prototypical Network yang digunakan memiliki arsitektur ringan dengan backbone ResNet-34 yang telah dimodifikasi menyebabkan propagasi gradien yang cepat dan inferensi secara *real-time*. Waktu pelatihan rata-rata per episode tercatat sebesar 0.83 detik dan waktu inferensi per batch sebesar 0.0273 detik. Hasil ini menunjukkan bahwa proses pelatihan sangat efisien untuk dapat diterapkan pada lingkungan dengan sumber daya yang terbatas.

4. KESIMPULAN

Hasil penelitian telah menunjukkan bahwa pendekatan FSL dengan arsitektur Prototypical Network berbasis ResNet-34 mampu secara efektif mengklasifikasikan spesies nyamuk meskipun dalam kondisi keterbatasan data latih. Dengan memanfaatkan hanya sejumlah kecil contoh per kelas (*K-shot*), model mampu membangun representasi fitur yang diskriminatif dan menghasilkan kinerja klasifikasi yang tinggi. Berdasarkan hasil evaluasi,

model mencapai akurasi sebesar 96,33% yang menunjukkan kemampuan generalisasi yang sangat baik pada skenario pengujian antar *fold*. Selain performa klasifikasi yang unggul, model juga menunjukkan efisiensi komputasi yang tinggi, dengan waktu pelatihan dan inferensi yang relatif cepat serta konsumsi sumber daya komputasi yang minimal. Hasil ini menegaskan bahwa pendekatan FSL sistem ini berpotensi digunakan oleh petugas lapangan atau Dinas Kesehatan untuk identifikasi cepat spesies nyamuk vektor menggunakan citra dari mikroskop digital atau kamera smartphone, sehingga dapat mempercepat surveilans vektor dan pengendalian penyakit berbasis bukti. Pengembangan lanjutan sistem ini dapat difokuskan pada integrasi dengan perangkat *edge computing*, penerapan pada klasifikasi terbuka (*open-set recognition*), serta eksplorasi arsitektur *lightweight* untuk meningkatkan skalabilitas sistem. Penelitian ini memiliki beberapa keterbatasan, yaitu jumlah data pelatihan yang terbatas yaitu hanya mencakup tiga spesies nyamuk, dan belum diuji pada data lapangan nyata dengan kondisi pencahayaan dan posisi tubuh nyamuk yang bervariasi. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas jumlah spesies, meningkatkan ukuran dataset, serta mengeksplorasi integrasi model ke aplikasi mobile pada sistem surveilans untuk mendukung implementasi real-time di lapangan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Institut Teknologi Sumatera untuk pendanaan hibah penelitian (No. 1998z/IT9.2.1/PT.01.03/2025) melalui “Hibah Penelitian ITERA 2025”.

DAFTAR PUSTAKA

- [1] L. Facchinelli, A. Badolo, and P. J. McCall, “Biology and Behaviour of *Aedes aegypti* in the Human Environment: Opportunities for Vector Control of Arbovirus Transmission,” Mar. 01, 2023, *MDPI*. doi: 10.3390/v15030636.
- [2] N. Yurayart, M. Kaewthamasorn, and S. Tiawsirisup, “Vector competence of *Aedes albopictus* (Skuse) and *Aedes aegypti* (Linnaeus) for *Plasmodium gallinaceum* infection and transmission,” *Vet Parasitol*, vol. 241, pp. 20–25, Jul. 2017, doi: 10.1016/J.VETPAR.2017.05.002.
- [3] M. A. Saleem and I. Lobanova, “Mosquito-borne diseases,” *Dengue Virus Disease: From Origin to Outbreak*, pp. 57–83, Jan. 2020, doi: 10.1016/B978-0-12-818270-3.00005-9.
- [4] M. Gómez, D. Martinez, M. Muñoz, and J. D. Ramírez, “*Aedes aegypti* and *Ae. albopictus* microbiome/virome: new strategies for controlling arboviral transmission?,” *Parasit Vectors*, vol. 15, no. 1, p. 287, 2022, doi: 10.1186/s13071-022-05401-9.
- [5] J. Roberts, K. H. Kenyon, A. Kwarteng, and E. K. A. Amewu, “Lymphatic filariasis as an indigenous illness: the local context of a global disease,” *SSM - Qualitative Research in Health*, vol. 8, p. 100598, Dec. 2025, doi: 10.1016/J.SSMQR.2025.100598.
- [6] J. I. Blanford, “Managing vector-borne diseases in a geoAI-enabled society. Malaria as an example,” *Acta Trop*, vol. 260, p. 107406, Dec. 2024, doi: 10.1016/J.ACTATROPICA.2024.107406.
- [7] T. Chaiphongpachara *et al.*, “Geometric morphometric and molecular techniques for discriminating among three cryptic species of the *Anopheles barbirostris* complex (Diptera: Culicidae) in Thailand,” *Heliyon*, vol. 8, no. 10, Oct. 2022, doi: 10.1016/j.heliyon.2022.e11261.
- [8] K. Nolte, F. G. Sauer, J. Baumbach, P. Kollmannsberger, C. Lins, and R. Lühken, “Robust mosquito species identification from diverse body and wing images using deep learning,” *Parasit Vectors*, vol. 17, no. 1, p. 372, 2024, doi: 10.1186/s13071-024-06459-3.
- [9] S. Lee, H. Kim, and B.-K. Cho, “Deep Learning-Based Image Classification for Major Mosquito Species Inhabiting Korea,” *Insects*, vol. 14, no. 6, 2023, doi: 10.3390/insects14060526.
- [10] A. A. J. Karim, M. Z. Mahmud, and R. Khan, “Advanced vision transformers and open-set learning for robust mosquito classification: A novel approach to entomological studies,” *PLoS Comput Biol*, vol. 20, no. 12, pp. e1012654–, Dec. 2024, [Online]. Available: <https://doi.org/10.1371/journal.pcbi.1012654>
- [11] E. Pachetti and S. Colantonio, “A systematic review of few-shot learning in medical imaging,” *Artif Intell Med*, vol. 156, p. 102949, Oct. 2024, doi: 10.1016/J.ARTMED.2024.102949.
- [12] J. Snell, K. Swersky, and R. Zemel, “Prototypical networks for few-shot learning,” in *Proceedings of the 31st International Conference on Neural Information Processing Systems*, in NIPS’17. Red Hook, NY, USA: Curran Associates Inc., 2017, pp. 4080–4090.

-
- [13] B. P. Amiruddin and R. E. Abdul Kadir, "CNN Architectures Performance Evaluation for Image Classification of Mosquito in Indonesia," in *2020 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 2020, pp. 223–227. doi: 10.1109/ISITIA49792.2020.9163732.
- [14] S. Lee, H. Kim, and B.-K. Cho, "Deep Learning-Based Image Classification for Major Mosquito Species Inhabiting Korea," *Insects*, vol. 14, no. 6, 2023, doi: 10.3390/insects14060526.
- [15] Z. Jiang, Z. Feng, and B. Niu, "Prototype-Neighbor Networks with task-specific enhanced meta-learning for few-shot classification," *Neural Networks*, vol. 190, p. 107761, Oct. 2025, doi: 10.1016/J.NEUNET.2025.107761.
- [16] G. Işık and İ. Paçal, "Few-shot classification of ultrasound breast cancer images using meta-learning algorithms," *Neural Comput Appl*, vol. 36, no. 20, pp. 12047–12059, Jul. 2024, doi: 10.1007/s00521-024-09767-y.
- [17] J. N. Eckardt *et al.*, "Deep learning identifies Acute Promyelocytic Leukemia in bone marrow smears," *BMC Cancer*, vol. 22, no. 1, Dec. 2022, doi: 10.1186/s12885-022-09307-8.
- [18] Ong Song Quan, "Mosquito on human skin," *Mendeley Data*, Jun. 2022, doi: 10.17632/zw4p9kj6nt.2.
- [19] N. Ragu and J. Teo, "Pest classification: Explainable few-shot learning vs. convolutional neural networks vs. transfer learning," *Sci Afr*, vol. 27, p. e02512, Mar. 2025, doi: 10.1016/J.SCIAF.2024.E02512.