

Evaluasi Parameter *Flower Pollination Neural Network* untuk Deteksi Malaria dan Dengue

<http://dx.doi.org/10.28932/jutisi.v12i2.13471>

Riwayat Artikel

Received: 05 Oktober 2025 | Final Revision: 08 April 2026 | Accepted: 10 April 2026

Creative Commons License 4.0 (CC BY – NC)



Bernardino Antonius Kase^{✉#1}, Yulianto Triwahyuadi Polly^{#2}, Yelly Yosiana Nabuasa^{#3}, Adriana Fanggaldae^{#4}

[#] Program Studi Ilmu Komputer, Universitas Nusa Cendana
Jln. Adisucipto – Penfui, Kota Kupang, 85001, Indonesia

¹bernardinokase@gmail.com

²yuliantopolly@staf.undana.ac.id

³yellynabuasa@staf.undana.ac.id

⁴adrianafanggaldae@staf.undana.ac.id

[✉]Corresponding author: bernardinokase@gmail.com

Abstrak — Sebagai ibukota Provinsi Nusa Tenggara Timur (NTT), Kota Kupang menghadapi permasalahan serius terkait pengelolaan sampah. Penumpukan sampah yang tidak tertangani dengan baik memicu genangan air dan menciptakan habitat ideal bagi nyamuk untuk berkembang biak, sehingga meningkatkan risiko persebaran penyakit seperti Demam Berdarah Dengue (DBD) dan Malaria. Kelompok usia 0-20 tahun serta jenis kelamin wanita cenderung memiliki tingkat kejadian DBD yang tinggi, sedangkan malaria paling rentan terhadap anak kecil yang belum memiliki kekebalan terhadap malaria dan wanita hamil yang kekebalannya berkurang dikarenakan kehamilannya. Untuk mengatasi tantangan ini, penelitian ini mengusulkan sebuah pendekatan yaitu, *Flower Pollination Neural Network* (FPNN), untuk mengklasifikasi penyakit DBD dan malaria. FPNN merupakan gabungan dari *Neural Network* (NN) yang dioptimalkan menggunakan *Flower Pollination Algorithm* (FPA). FPA merupakan algoritma metaheuristik dan sering menggunakan pencarian secara stokastik. FPA dapat mengoptimalkan bobot NN dan menghindari jebakan local optima, serta dapat meminimalisir kesalahan pada NN. Pengujian pada penelitian ini menggunakan *10-fold cross validation* untuk melihat kemampuan FPNN dalam menggeneralisasi data yang belum pernah dipelajari. Hasil dari pengujian diperoleh kombinasi parameter *switch probability* 0,7; 15 *neuron* pada *hidden layer*; 25 populasi memberikan hasil terbaik dengan nilai akurasi 86,4% dan f1-score 72,312%. Kombinasi parameter ini memberikan hasil akurasi yang baik, meskipun tidak lebih dari pembandingan yang lain, kombinasi parameter ini memberikan hasil akurasi yang konsisten dan menunjukkan kemampuan generalisasi data yang baik. Sementara pada f1-score, kombinasi ini memberikan hasil tertinggi dan dapat dikatakan baik karena mampu memberikan keseimbangan antara kemampuan pengenalan pola pelatihan dan memprediksi data yang belum pernah dipelajari.

Kata kunci — Demam Berdarah Dengue; *Flower Pollination Neural Network* (FPNN); Malaria; Sampah.

Parameters Evaluation of *Flower Pollination Neural Network* for Malaria and Dengue Detection

Abstract — As the capital city of East Nusa Tenggara Province (NTT), Kupang City faces serious issues related to waste management. The accumulation of unmanaged waste leads to water stagnation and creates ideal breeding grounds for mosquitoes, thereby increasing the risk of disease transmission such as Dengue Fever (DBD) and Malaria. Individuals aged 0–20 years and females tend to have

higher rates of DBD, while malaria most commonly affects young children who have not yet developed immunity and pregnant women whose immunity is reduced due to pregnancy. To address this challenge, this study proposes a novel approach: the Flower Pollination Neural Network (FPNN) for classifying DBD and malaria cases. FPNN is a hybrid model combining Neural Networks (NN) optimized using the Flower Pollination Algorithm (FPA). FPA is a metaheuristic algorithm that often employs stochastic search. It is capable of optimizing the weights of NN, avoiding local optima traps, and minimizing errors in NN. This study uses 10-fold cross-validation to evaluate FPNN's ability to generalize to unseen data. The best results were achieved using a parameter combination of switch probability 0.7, 15 neurons in the hidden layer, and a population size of 25, yielding an accuracy of 86.4% and an F1-score of 72.312%. Although this parameter combination does not outperform all others in terms of accuracy, it consistently delivers good accuracy and demonstrates strong data generalization capabilities. Furthermore, it achieved the highest F1-score, indicating a good balance between pattern recognition during training and prediction performance on unseen data.

Keywords— Dengue Fever; Flower Pollination Neural Network (FPNN); Malaria; Waste.

I. PENDAHULUAN

Penyakit akibat gigitan nyamuk merupakan masalah serius dalam bidang kesehatan, termasuk Indonesia [1]. Menurut WHO, penyakit ini menjadi perhatian global [2]. Data Badan Pusat Statistik (BPS) pada tahun 2018 mencatat 1.384.238 kasus di Indonesia, dengan 332.815 kasus di Provinsi Nusa Tenggara Timur (NTT) [3]. Penyakit yang disebabkan oleh gigitan nyamuk seperti demam berdarah *dengue* (DBD) yang disebabkan oleh virus *dengue* yang dibawa oleh nyamuk *Aedes aegypti* [4] dan Malaria yang menyebar melalui gigitan nyamuk *Anopheles spp* yang membawa parasit *Plasmodium* [2]. Faktor lingkungan seperti sanitasi dan pengolahan sampah, turut mempengaruhi pola penyebaran di lingkungan masyarakat.

Kota Kupang, sebagai ibu kota Provinsi NTT menghadapi permasalahan serius terkait pengelolaan sampah yang belum optimal [5]. Produksi sampah harian di Kota Kupang tergolong tinggi, yakni mencapai 234 ton/hari. Namun keterbatasan armada pengangkut dan rendahnya disiplin tenaga operasional mengakibatkan penumpukan sampah di sejumlah titik Tempat Pembuangan Sementara (TPS) [6]. Rendahnya kesadaran masyarakat terhadap pengelolaan sampah [7] memperburuk kondisi ini, menyebabkan terbentuknya genangan air di sekitar tumpukan sampah yang menjadi tempat habitat ideal bagi perkembangbiakan nyamuk [8]. situasi ini secara langsung meningkatkan risiko persebaran penyakit DBD dan malaria di wilayah Kota Kupang.

Annual Parasite Incidence (API) merupakan indikator yang mengukur jumlah kasus malaria per 1.000 penduduk dalam satu tahun. Di Kota Kupang, terjadi peningkatan nilai API yang signifikan dari 0,09 pada tahun 2019 menjadi 0,87 pada tahun 2020, lalu turun menjadi 0,03 pada tahun 2021. Pola serupa terjadi pada kasus DBD, sebesar 156,6 per 100.000 penduduk pada tahun 2019, meningkat menjadi 184 per 100.000 penduduk pada tahun 2020, lalu turun menjadi 142,7 per 100.000 penduduk pada tahun 2021 [9].

Pemanfaatan teknologi menjadi langkah strategis dalam mengidentifikasi penyakit akibat gigitan nyamuk secara efisien dan akurat. Perkembangan teknologi semakin banyak dimanfaatkan dalam bidang medis, termasuk pengelolaan data, diagnosis, pematuhan, dan evaluasi penyakit di wilayah tertentu ([10], [11]). Salah satu teknologi yang digunakan adalah kecerdasan buatan, seperti sistem pakar dan jaringan saraf tiruan (JST).

Sistem pakar merupakan bagian kecerdasan buatan yang mampu meniru perilaku seorang ahli dalam mendiagnosis penyakit [12]. Sistem ini menggunakan basis pengetahuan pakar yang disusun dalam format *knowledge base* atau *rule base* (*IF-THEN*) ([1], [13]). Representasi pengetahuan merupakan hal terpenting, dan efisiensinya dapat ditingkatkan dengan menggabungkan beberapa *rule base* [14]. Namun, sistem pakar sangat bergantung pada pola pengetahuan pakar, sehingga rentan terhadap ketidakpastian dan keterbatasan representasi pengetahuan pakar [15].

Jaringan Saraf Tiruan (JST) atau *Neural Network* (NN) adalah sekelompok unit pemrosesan kecil yang karakteristiknya menyerupai jaringan saraf biologis manusia [16]. NN banyak digunakan dalam klasifikasi, prediksi dan pengenalan pola data [17], karena kemampuannya untuk mendeteksi pola dan hubungan dalam data. Namun, NN sering terjebak dalam local optima yang menurunkan kemampuan pengenalan pola ([18], [19]), serta penentuan bobot yang kurang optimal dalam klasifikasi [20]. Permasalahan ini dapat diatasi dengan menggunakan algoritma metaheuristik seperti *Flower Pollination Algorithm* (FPA), yang membantu NN menghindari jebakan local optima dan meminimalisir kesalahan [10].

Metaheuristik merupakan suatu metode untuk mencari solusi yang menggabungkan pencarian lokal dan kemampuan keluar dari local optima dengan membangkitkan solusi terbaik secara iteratif [21]. FPA merupakan salah satu algoritma metaheuristik yang terinspirasi dari proses penyerbukan (polinasi) pada bunga yang disebabkan oleh polinator di alam, dimana bunga yang terpolinasi adalah bunga dengan penampilan yang terbaik [22]. FPA menggunakan pendekatan stokastik, efisien, konsisten dan mampu menangani optimasi multi objek serta sudah diimplementasikan di dalam dunia medis dan terbukti mampu memberikan hasil akurasi yang baik ([10], [23], [24]).

Meskipun telah banyak dilakukan penelitian menggunakan sistem pakar dan jaringan saraf tiruan untuk mengklasifikasi penyakit DBD dan malaria ([25], [26], [27], [28]), masih terdapat kelemahan dari hasil akurasi dan kemampuan generalisasi terhadap data baru, serta keterbatasan dalam optimasi parameter yang berpengaruh terhadap kinerja model secara

keseluruhan. Penelitian ini menggunakan pendekatan yang menggabungkan NN dengan FPA yang kemudian disebut *Flower Pollination Neural Network* (FPNN) untuk mengidentifikasi dan mengklasifikasi data penyakit DBD dan malaria. Pengujian yang dilakukan dalam penelitian ini menggunakan *10-fold cross validation* sebanyak 5 kali untuk memastikan konsistensi dan keandalan hasil evaluasi model terhadap kombinasi parameter *switch probability*; *neuron* pada *hidden layer*; dan populasi. Tujuan dari penelitian ini adalah untuk mengembangkan NN yang dioptimalkan bobotnya menggunakan FPA, sehingga diharapkan dapat meningkatkan akurasi klasifikasi serta menilai kemampuan generalisasi terhadap data baru. Selain itu, penelitian ini juga bertujuan untuk menganalisis kinerja model FPNN terhadap kombinasi parameter yang memberikan rata-rata akurasi dan f1-score terbaik dari seluruh pembandingnya.

II. METODE PENELITIAN

A. Sumber dan Jenis Data

Dataset yang digunakan dalam penelitian ini berfokus pada data penyakit akibat gigitan nyamuk. Data ini mencakup informasi mengenai kasus-kasus penyakit yang ditularkan melalui nyamuk, seperti Demam Berdarah Dengue (DBD) dan Malaria. Dataset yang digunakan adalah kumpulan data gejala klinis yang diambil pada tahun 2019-2024 di Rumah Sakit Umum Daerah (RSUD) Prof. Dr. W Z Johannes Kota Kupang.

B. Preprocessing Data

Preprocessing data dilakukan untuk memastikan kualitas dan konsistensi data yang akan digunakan dalam pelatihan model. Tahapan ini mencakup penghapusan duplikasi data, penanganan data yang hilang (*missing value*) dan mengkonversi data ke format biner (1 = ada, 0 = tidak ada). Nilai 0 pada dataset bukan merupakan hasil imputasi *missing value*, melainkan representasi kondisi klinis dimana gejala tersebut tidak muncul pada pasien (dataset yang digunakan tidak mengandung *missing value*). Selanjutnya data akan diklasifikasi ke dalam beberapa kelas. Diketahui terdapat 40 fitur penyakit akibat gigitan nyamuk (dapat dilihat pada tabel 1) dan 2 target penyakit akibat gigitan nyamuk yaitu Demam Berdarah Dengue (DBD) dan Malaria (dapat dilihat pada tabel 2), kemudian seluruh fitur input dipetakan dalam bentuk nilai bagi vektor input e (dapat dilihat pada tabel 3) dan target dipetakan ke dalam bentuk biner (dapat dilihat pada tabel 4). Total jumlah data setelah dilakukan *preprocessing* sebanyak 100 data (72 data DBD dan 28 Malaria).

Keterbatasan jumlah data serta distribusi kelas dataset dipengaruhi oleh ketersediaan data selama periode penelitian dan mencerminkan distribusi kasus yang terjadi secara alami di lapangan.

TABEL 1
FITUR PENYAKIT AKIBAT GIGITAN NYAMUK

Kode Fitur	Nama Fitur	Kode Fitur	Nama Fitur	Kode Fitur	Nama Fitur	Kode Fitur	Nama Fitur
G1	Usia 0-5 Tahun	G11	Tensi Darah Diastolik 60 – 80 mmHg	G21	Demam > 2 Hari	G31	Bintik Merah Pada Kulit
G2	Usia 6-17 Tahun	G12	Tensi Darah Sistolik > 140 mmHg	G22	Tingkat Kesadaran Normal	G32	Tidak BAK > 8 jam
G3	Usia > 18 Tahun	G13	Tensi Darah Diastolik > 90 mmHg	G23	Kejang	G33	Nafsu Makan Menurun
G4	Suhu Tubuh 36 – 37,5°C	G14	Denyut Nadi 100 – 160 bpm	G24	Gusi Berdarah	G34	Sesak Nafas
G5	Suhu Tubuh 37,6 – 38 °C	G15	Denyut Nadi 70 – 120 bpm	G25	Mimisan	G35	Berkeringat
G6	Suhu Tubuh 38,1 – 39 °C	G16	Denyut Nadi 60 – 100 bpm	G26	Mual	G36	Mengigil
G7	Suhu Tubuh > 39 °C	G17	RR 30 – 50 x/menit	G27	Muntah > 2x sehari	G37	Nyeri Otot
G8	Tensi Darah Sistolik < 90 mmHg	G18	RR 20 – 30 x/menit	G28	Nyeri Pada Perut atau Uluhati	G38	Nyeri Sendi
G9	Tensi Darah Diastolik < 60 mmHg	G19	RR 12 – 20 x/menit	G29	Diare	G39	Nyeri Kepala
G10	Tensi Darah Sistolik 90 – 130 mmHg	G20	SPO2 95 – 100%	G30	Lemas	G40	Warna Kulit Normal

TABEL 2
TARGET PENYAKIT AKIBAT GIGITAN NYAMUK

Kode Target	Nama Target
P1	Malaria
P2	DBD

TABEL 3
PEMETAAN FITUR INPUT PENYAKIT PADA MANUSIA DALAM BENTUK NILAI BAGI VEKTOR INPUT

Kode Fitur	Nilai Bagi Vektor Input e ("YA = 1" atau "TIDAK = 0")	Kode Fitur	Nilai Bagi Vektor Input e ("YA = 1" atau "TIDAK = 0")
G1	1 atau 0	G21	1 atau 0
G2	1 atau 0	G22	1 atau 0
G3	1 atau 0	G23	1 atau 0
G4	1 atau 0	G24	1 atau 0
G5	1 atau 0	G26	1 atau 0
G6	1 atau 0	G25	1 atau 0
G7	1 atau 0	G27	1 atau 0
G8	1 atau 0	G28	1 atau 0
G9	1 atau 0	G29	1 atau 0
G10	1 atau 0	G30	1 atau 0
G11	1 atau 0	G31	1 atau 0
G12	1 atau 0	G32	1 atau 0
G13	1 atau 0	G33	1 atau 0
G14	1 atau 0	G34	1 atau 0
G15	1 atau 0	G35	1 atau 0
G16	1 atau 0	G36	1 atau 0
G17	1 atau 0	G37	1 atau 0
G18	1 atau 0	G38	1 atau 0
G19	1 atau 0	G39	1 atau 0
G20	1 atau 0	G40	1 atau 0

TABEL 4
PEMETAAN TARGET PENYAKIT AKIBAT GIGITAN NYAMUK KE DALAM FORMAT BINER

Kode Target	Nama Target	Nilai Vektor Target
P1	Malaria	1
P2	DBD	0

C. Flower Pollination Algorithm

Flower Pollination Algorithm (FPA) merupakan algoritma metaheuristik yang terinspirasi dari proses penyerbukan alam yang dijelaskan pada aturan berikut [22]:

1. Penyerbukan biotik dan penyerbukan silang dianggap sebagai proses penyerbukan global dengan penyerbuk membawa benang sari yang melakukan penerbangan jarak jauh.
2. Penyerbukan abiotik dan penyerbukan sendiri dianggap sebagai penyerbukan lokal karena penyerbukan terjadi dalam jarak yang dekat.
3. Keteguhan bunga atau peluang reproduksi yang sebanding dengan kemiripan antara dua bunga.
4. Aturan 1 dan 2 diatur oleh peluang berpindah atau *switch probability*.

Pada penyerbukan global, penyerbuk seperti serangga dan hewan membawa serbuk sari dalam jarak yang jauh. Hal ini menjamin suatu solusi dengan hasil yang terbaik, solusi terbaik direpresentasikan dengan g^* , maka aturan 1 dan 3 dapat dinyatakan dengan persamaan (1).

$$x_i^{t+1} = x_i^t + \gamma L(g^* - x_i^t) \quad (1)$$

Dimana x_i^t adalah serbuk sari i atau vektor solusi ke- i pada iterasi t , g^* adalah vektor solusi terbaik saat ini, γ adalah faktor penskalaan yang mengontrol ukuran langkah dan L merupakan vektor langkah atau kekuatan penyerbukan. L pada Persamaan (1) menyatakan Levy flight. Fungsi Levy dapat dinyatakan dengan persamaan (2).

$$L \sim \frac{\lambda \Gamma(\lambda) \sin(\frac{\pi\lambda}{2})}{\pi} \frac{1}{S^{1+\lambda}}, S \gg S_0 > 0 \quad (2)$$

$\Gamma(\lambda)$ adalah fungsi gamma standar dan $\lambda = 1,5$, distribusi Levy bernilai benar ketika $S > 0$, dan S ditentukan dari distribusi Gaussian U dan V , seperti pada persamaan (3).

$$S = \frac{U}{|V|^{\frac{1}{\lambda}}}, U \sim N(0, \sigma^2) \text{ dan } V \sim N(0, 1) \quad (3)$$

Dimana $U \sim N(0, \sigma^2)$ menunjukkan bahwa distribusi normal Gaussian dengan variansi σ^2 dan rata-rata nol, dan $V \sim N(0, 1)$ menunjukkan distribusi normal Gaussian standar σ^2 dapat dihitung dengan persamaan (4).

$$\sigma^2 = \left\{ \frac{\Gamma(1+\lambda)}{\lambda \Gamma(\frac{1+\lambda}{2})} \frac{\sin(\frac{\pi\lambda}{2})}{2^{(\lambda-1)/2}} \right\} \quad (4)$$

Penyerbukan sendiri melibatkan penyerbuk seperti angin dan air, yang membawa serbuk sari dari tetangga terdekatnya, dengan aturan 2 dan 3 dapat dinyatakan dengan persamaan (5).

$$x_i^{t+1} = x_i^t + \varepsilon(x_j^t - x_k^t) \quad (5)$$

Dimana *random walk* ε adalah bilangan riil acak berdasarkan distribusi uniform yang memenuhi syarat $\varepsilon \in [0, 1]$, x_j^t dan x_k^t masing-masing adalah posisi terbaik serbuk sari j dan k .

Aktivitas penyerbukan dapat bersifat lokal atau global. Penyerbukan lokal sering diserbuki oleh bunga dari tetangga terdekatnya di dalam suatu lingkungan atau kawasan yang tidak terlalu jauh daripada serbuk sari yang berasal dari tempat yang jauh [29]. Sehingga untuk mengatur perpindahan antara penyerbukan lokal dan global digunakan *switch probability* (aturan 4).

D. K-Fold Cross Validation

K-fold Cross Validation adalah teknik evaluasi model dalam *machine learning* yang digunakan untuk mengevaluasi performa model. Cara kerja *k-fold cross validation* yakni membagi *dataset* menjadi sejumlah *folds* kumpulan data dan *cross validation* dilakukan sebanyak k kali putaran. Setiap kumpulan data terdapat *subset* yang akan bergiliran digunakan sebagai set *validation* sedangkan *subset* lainnya digunakan sebagai set *training* [30]. Hasil klasifikasi kemudian diuji efektivitasnya menggunakan Confusion Matrix untuk mendapatkan nilai akurasi, presisi, recall dan F1-score ([31], [32]).

Akurasi didefinisikan sebagai tingkat kedekatan antara nilai prediksi dengan nilai aktual. Persamaan (6) adalah fungsi yang digunakan untuk mengukur akurasi hasil klasifikasi.

$$\text{akurasi} = \frac{\sum \text{klasifikasi benar}}{\sum \text{data uji}} \times 100\% \quad (6)$$

Presisi didefinisikan sebagai rasio item relevan yang dipilih terhadap semua item yang terpilih atau dapat diartikan sebagai kecocokan antara permintaan informasi dengan jawaban terhadap permintaan tersebut. Persamaan (7) adalah fungsi yang digunakan untuk mengukur nilai presisi.

$$\text{precision} = TP / (TP + FP) \quad (7)$$

Recall didefinisikan sebagai rasio dari item relevan yang dipilih terhadap total jumlah item relevan yang tersedia. Persamaan (8) adalah fungsi yang digunakan untuk mengukur nilai recall.

$$\text{recall} = TP / (TP + FN) \quad (8)$$

F1-score adalah matrik evaluasi yang menggabungkan *precision* dan *recall*. Persamaan (9) adalah fungsi yang digunakan untuk mengukur nilai F1-score.


$$F_1 = 2 \times \frac{(\text{precision} \times \text{recall})}{(\text{precision} + \text{recall})} \quad (9)$$

E. Flower Pollination Neural Network (FPNN)

Flower Pollination Neural Network (FPNN) adalah sebuah algoritma yang menggabungkan *Feed Forward Neural Network* (FFNN) dengan *Flower Pollination Algorithm* (FPA). FPA digunakan untuk mengoptimalkan bobot dan bias pada FFNN, dengan tujuan untuk mengoptimalkan kinerja model *Neural Network* pada proses pelatihan, khususnya dalam menemukan solusi optimal dan menghindari jebakan local minima. *Flowchart* FPNN dapat dilihat pada gambar 1.

Pada gambar 1 tahapan pertama yang dilakukan model yaitu menerima data inputan berupa data fitur-fitur penyakit akibat dari gigitan nyamuk. Data akan di konversi ke dalam bilangan biner agar nilai input dan data uji bisa disesuaikan dengan fungsi aktivasi sigmoid yang akan digunakan dan diklasifikasi agar mendapatkan label yang sesuai sehingga jaringan tidak mengalami kegagalan ketika melakukan proses pelatihan dan pengujian. Menentukan nilai iterasi, populasi, dan switch probability. Kemudian menginisialisasi bobot awal dan bias awal, untuk memulai proses pelatihan atau pengujian dari titik tertentu. Inisialisasi bobot ini dilakukan secara random.

Langkah selanjutnya dilakukan pembangkitan populasi dengan solusi acak dan mencari nilai *fitness* terbaik pada awal pembangkitan populasi. Kemudian masuk pada proses berikutnya adalah mencari *fitness* terbaik di setiap iterasi yang ada. Dalam proses ini sejumlah populasi akan dikerjakan, kemudian akan masuk pada proses penyerbukan. Proses penyerbukan akan dilakukan dengan membangkitkan nilai acak. Apabila nilai acak kurang dari nilai *switch probability*, maka akan dilakukan proses penyerbukan global, sebaliknya akan dilakukan penyerbukan lokal. Kemudian hasil dari penyerbukan global atau lokal berupa solusi baru akan dihitung agar mendapatkan nilai *fitness* baru. Jika nilai *fitness* dari solusi baru $x_i^{t+1} < \text{nilai fitness } x_i^t$ atau sebelumnya, maka $x_i^t = x_i^{t+1}$. Proses ini akan diulang sampai n jumlah populasi terpenuhi. Setelah itu, *fitness* terbaik akan dicari pada N_pop tersebut. Selanjutnya proses akan diulang sampai kondisi penghentian *training* terpenuhi untuk mendapatkan bobot terbaik dengan nilai *fitness* terkecil.



Gambar 1. Flowchart flower pollination neural network (FPNN)

F. Penyakit Akibat Gigitan Nyamuk

- 1) *Demam Berdarah Dengue (DBD)*: Demam Berdarah *Dengue* (DBD) adalah infeksi yang disebabkan oleh virus *dengue* yang ditularkan ke manusia melalui gigitan nyamuk *Aedes aegypti* betina yang sudah terinfeksi. Virus *dengue* dapat hidup di alam melalui transmisi vertikal dalam tubuh nyamuk, dimana virus yang ditularkan oleh nyamuk betina ke telurnya yang nantinya akan menjadi nyamuk. Virus juga dapat ditularkan dari nyamuk jantan kepada nyamuk betina melalui kontak seksual. Selain itu, virus ditularkan saat nyamuk menggigit manusia yang darahnya mengandung virus *dengue*. Setelah mencapai lambung nyamuk, virus akan bereplikasi (berkembang biak/memecah diri), lalu bermigrasi sehingga akhirnya mencapai kelenjar ludah [33].

a. Kriteria klinis

- Demam tinggi yang muncul dalam waktu antara 2-7 hari, mencapai suhu 40°C. biasanya demam tinggi disertai dengan gejala yang tidak spesifik, seperti munculnya bintik-bintik kemerahan (*flusing*), tidak nafsu makan (*anoreksia*), badan lemas (*malaise*), dan nyeri sendi, tulang, serta terdapat rasa sakit di daerah bola mata (*retro-orbita*).
- Pembesaran pada daerah organ hati (*hepatomegali*).

- Muncul tanda-tanda pendarahan seperti mimisan (*epitaxis*), pendarahan pada kulit, pendarahan pada gusi, serta pada saat BAB disertai dengan pendarahan berwarna merah agak kehitaman (*melena*).
- Kegagalan sirkulasi darah yang ditandai dengan denyut nadi yang teraba lemah dan cepat, pada ujung jari terasa dingin, dan juga dapat disertai shock yang dapat menyebabkan kematian.

b. Kriteria laboratorium

- Penurunan jumlah trombosit (*trombositopenia*) $\leq 100.000/\text{mm}^3$.
- Peningkatan kadar hematokrit $> 20\%$ dari kadar normal.

2) *Malaria*: Malaria adalah salah satu jenis penyakit menular yang disebabkan oleh parasit *Plasmodium* yang ditularkan melalui gigitan nyamuk *Anopheles sp* betina yang terinfeksi. Malaria pada manusia dapat disebabkan oleh *Plasmodium malariae*, *Plasmodium Vivax*, *Plasmodium Falciparum*, dan *Plasmodium Ovale* [34]. Gejala klinis yang ditimbulkan akibat dari penyakit malaria antara lain sebagai berikut:

- Badan terasa lemas dan pucat karena kekurangan darah dan berkeringat, nafsu makan menurun.
- Mual-mual kadang-kadang diikuti muntah.
- Sakit kepala yang berat, terus-menerus, khususnya pada infeksi *Plasmodium Falciparum*.
- Jika terlambat ditangani maka akan terjadi pembesaran limpa.
- Malaria berat, seperti gejala di atas disertai kejang-kejang dan penurunan.
- Pada anak, gejala yang timbul seperti anemia berat, mencret (Diare), dan gangguan pernapasan.

G. Pengujian Parameter Flower Pollination Neural Network (FPNN)

Hasil identifikasi penyakit akibat gigitan nyamuk yang diperoleh akan diuji untuk menilai akurasi serta memastikan kesesuaian dengan hipotesis yang telah ditetapkan sebelumnya. Hasil pengujian diperoleh dengan menguji tingkat akurasi dan F1-score menggunakan *k-fold cross validation*. Skenario pengujian yang akan dilakukan menggunakan *10-fold cross validation* sebanyak 5 (lima) kali percobaan, parameter pengujian yang digunakan meliputi nilai *switch probability* sebesar 0,5;0,6;0,7;0,8, nilai *hidden layer* sebesar 5;10;15, jumlah populasi sebanyak 20;25;30, MSE (0,001), serta *stopping criteria training (fitness < MSE)* atau maksimal iterasi 10.000, dataset akan dibagi menjadi 10 subset dengan ukuran yang kurang lebih sama. Pelatihan akan dilakukan berulang sebanyak 10 kali dimana 9 subset digunakan untuk melatih model dan 1 subset digunakan untuk menguji model. Setelah mencapai *stopping criteria*, rata-rata dari semua hasil pengujian akan dihitung untuk mendapatkan gambaran umum tentang performa model. Parameter pengujian dapat dilihat pada tabel 5 dan rekapitulasi kombinasi parameter dapat dilihat pada tabel 6.

TABEL 5
TABEL PARAMETER PENGUJIAN

No	Parameter	Nilai yang diuji
1	<i>Switch Probability</i>	0,5; 0,6; 0,7; 0,8
2	Jumlah neuron pada <i>Hidden layer</i>	5, 10, 15
3	Jumlah Populasi	20, 25, 30
4	MSE	0,001
5	Faktor pengali	0,01
6	Iterasi	10000
7	{Batas Atas, Batas Bawah}	{15, -15}
8	Perulangan <i>k-fold</i>	5

TABEL 6
REKAPITULASI KOMBINASI PARAMETER PENGUJIAN

No	<i>Switch Probability</i>	Jumlah neuron pada <i>Hidden layer</i>	Populasi	No	<i>Switch Probability</i>	Jumlah neuron pada <i>Hidden layer</i>	Populasi
1	0,5	5	20	19	0,7	5	20
2	0,5	5	25	20	0,7	5	25
3	0,5	5	30	21	0,7	5	30
4	0,5	10	20	22	0,7	10	20
5	0,5	10	25	23	0,7	10	25

No	Switch Probability	Jumlah neuron pada Hidden layer	Populasi	No	Switch Probability	Jumlah neuron pada Hidden layer	Populasi
6	0,5	10	30	24	0,7	10	30
7	0,5	15	20	25	0,7	15	20
8	0,5	15	25	26	0,7	15	25
9	0,5	15	30	27	0,7	15	30
10	0,6	5	20	28	0,8	5	20
11	0,6	5	25	29	0,8	5	25
12	0,6	5	30	30	0,8	5	30
13	0,6	10	20	31	0,8	10	20
14	0,6	10	25	32	0,8	10	25
15	0,6	10	30	33	0,8	10	30
16	0,6	15	20	34	0,8	15	20
17	0,6	15	25	35	0,8	15	25
18	0,6	15	30	36	0,8	15	30

III. HASIL DAN PEMBAHASAN

Pengujian dilakukan menggunakan kombinasi parameter *switch probability*, jumlah *neuron* pada *hidden layer* dan populasi yang dapat dilihat pada tabel 6 (rekapitulasi kombinasi parameter pengujian) terhadap dataset penyakit akibat gigitan nyamuk sebanyak 100 data menggunakan 10-fold cross validation dengan percobaan sebanyak 5 kali.

A. Pengujian Berdasarkan Akurasi

Unjuk kerja model pembelajaran FPNN dievaluasi berdasarkan akurasi klasifikasi tertinggi dari hasil pengujian menggunakan rata-rata akurasi 5 percobaan 10-fold cross validation dari validation dataset untuk melihat kemampuan model dalam menggeneralisasi data baru, kemudian diamati dengan akurasi klasifikasi pada actual training dataset. Evaluasi setiap percobaan dilakukan dengan menghitung rata-rata akurasi setiap fold dengan kombinasi parameter yang berbeda.

Hasil akurasi rata-rata dari 36 kombinasi parameter Flower Pollination Algorithm (FPA) terhadap akurasi pada validation data test dan actual training dataset dapat dilihat pada tabel 7. Tujuan Utama dari pengujian ini adalah untuk memilih kombinasi parameter yang menghasilkan akurasi tertinggi secara konsisten antara data training dan validation, sehingga diperoleh model yang stabil, generalis, dan tidak overfit.

Nilai akurasi tertinggi pada validation dataset diperoleh pada switch probability 0,7; 15 neuron pada hidden layer; dan 25 populasi dengan nilai akurasi validation = 86,4% (Model nomor 26, ditandai dengan warna hijau pada tabel 7 kolom rata-rata akurasi validation dataset (%)). Nilai akurasi tertinggi pada actual training dataset diperoleh pada switch probability 0,5; 10 neuron pada hidden layer; dan 20 populasi dengan nilai akurasi actual training dataset = 91,11% (Model nomor 4, ditandai dengan warna hijau pada tabel 7 pada kolom rata-rata akurasi actual training dataset (%)). Tingginya nilai akurasi pada validation dan actual training dataset mengindikasikan bahwa model telah berhasil mempelajari pola-pola data validasi dan data training dengan sangat baik, namun nilai akurasi pada actual training dataset yang terlalu tinggi menunjukkan bahwa model terlalu menyesuaikan diri dengan pola pelatihan. Jika dibandingkan dengan nilai rujukannya terhadap actual training dan validation dataset, kedua model ini sama-sama memiliki potensi overfitting dikarenakan memiliki selisih 4,91% pada kombinasi parameter nomor 4 dan selisih 4,2% pada kombinasi parameter nomor 26.

Secara keseluruhan kombinasi parameter yang memberikan rata-rata akurasi klasifikasi tertinggi pada training dan validation dataset diperoleh pada switch probability 0,5; 10 neuron pada hidden layer; dan 20 populasi dengan nilai akurasi pada validation dan training sebesar 88,655% (Model nomor 4, pada tabel 7 ditandai dengan warna biru). Namun model dengan kombinasi parameter ini bukanlah yang terbaik dibandingkan Switch Probability 0,7; 15 neuron pada hidden layer; dan 25 populasi (Model nomor 26, pada tabel 7 ditandai dengan warna kuning). Alasan model nomor 26 lebih baik dari model nomor 4 dikarenakan selisih antara validation dan training dataset pada model nomor 4 (4,91%) lebih tinggi dibandingkan model nomor 26 (4,2%).

Hasil rekapitulasi pengujian pada tabel 8 ini membuktikan bahwa model pembelajaran dengan kombinasi parameter switch probability sebesar 0,7; 15 neuron pada hidden layer; dan populasi sebanyak 25 dengan nilai akurasi pada actual training dataset dan validation dataset sebesar 88,5% adalah yang tertinggi kedua dari seluruh pembandingan. Meskipun bukan merupakan yang tertinggi, hasil ini juga menjelaskan bahwa FPNN cukup baik dalam mengidentifikasi penyakit akibat gigitan nyamuk. Selain itu dapat dilihat pada tabel 9 setiap percobaan pada model nomor 26 lebih konsisten memberikan

hasil akurasi pada *validation* dataset. Sehingga model nomor 26 dapat dikatakan stabil dan mampu menggeneralisasi data yang belum pernah dipelajari.

TABEL 7
HASIL PENGUJIAN AKURASI 5 PERCOBAAN PADA ACTUAL TRAINING DATASET DAN VALIDATION DATASET

No	Parameter			Rata-rata akurasi <i>validation</i> dataset (%)	Rata-rata akurasi <i>actual training</i> dataset (%)	Rata-rata akurasi dari <i>actual training</i> dataset dan <i>validation</i> dataset (%)
	<i>Switch Probability</i>	Jumlah neuron pada <i>Hidden Layer</i>	Populasi			
1	0,5	5	20	81,6	90,156	85,878
2	0,5	5	25	81,6	90,534	86,067
3	0,5	5	30	80,8	89,842	85,321
4	0,5	10	20	86,2	91,11	88,655
5	0,5	10	25	82,4	90,666	86,533
6	0,5	10	30	84	90,69	87,345
7	0,5	15	20	80,6	90,268	85,434
8	0,5	15	25	82,6	90,8	86,7
9	0,5	15	30	81	90,288	85,644
10	0,6	5	20	83,2	90,176	86,688
11	0,6	5	25	82,6	90,576	86,588
12	0,6	5	30	81,2	90,488	85,844
13	0,6	10	20	81	90,398	85,699
14	0,6	10	25	83,4	90,802	87,101
15	0,6	10	30	80,6	90,954	85,777
16	0,6	15	20	80	90,466	85,233
17	0,6	15	25	84,4	90,824	87,612
18	0,6	15	30	80,8	90,642	85,721
19	0,7	5	20	80,4	90,29	85,345
20	0,7	5	25	83	90,134	86,567
21	0,7	5	30	83,6	90,6	87,1
22	0,7	10	20	81,6	90,62	86,11
23	0,7	10	25	77,6	90,578	84,089
24	0,7	10	30	83,8	90,42	87,11
25	0,7	15	20	82,6	89,98	86,29
26	0,7	15	25	86,4	90,6	88,5
27	0,7	15	30	81,4	90,688	86,044
28	0,8	5	20	81,8	90,288	86,044
29	0,8	5	25	81,6	90,688	86,144
30	0,8	5	30	81,2	90,442	85,821
31	0,8	10	20	81,8	90,334	86,067
32	0,8	10	25	82,4	90,378	86,389
33	0,8	10	30	80	90,4	85,2
34	0,8	15	20	82,4	90,778	86,589
35	0,8	15	25	84,4	90,49	87,445
36	0,8	15	30	82,8	90,314	86,557

TABEL 8
PARAMETER TERBAIK PADA PENGUJIAN BERDASARKAN AKURASI

Parameter			Rata-rata akurasi dari <i>actual training</i> dataset dan <i>validation</i> dataset (%)
<i>Switch Probability</i>	Jumlah <i>neuron</i> pada <i>Hidden layer</i>	Populasi	
0,7	15	25	88,5

TABEL 9
PERBANDINGAN RATA-RATA AKURASI 5 PERCOBAAN MODEL NOMOR 4 DAN 26 PADA VALIDATION DATASET

Parameter			Rata-rata akurasi <i>validation</i> dataset (%) pada percobaan ke-					Rata-rata 5 percobaan
<i>Switch Probability</i>	Jumlah <i>neuron</i> pada <i>Hidden layer</i>	Populasi	1	2	3	4	5	
0,5	10	20	83	81	90	96	81	86,2
0,7	15	25	84	86	89	88	85	86,4

B. Pengujian Berdasarkan F1-score

Unjuk kerja model pembelajaran FPNN berdasarkan f1-score tertinggi mengacu pada pemilihan kombinasi parameter yang memberikan akurasi klasifikasi tertinggi pada *validation* dataset (lihat tabel 7), kemudian diamati dengan f1-score pada *actual training* dataset. Kombinasi parameter terbaik pada pengujian akurasi klasifikasi dijadikan acuan dalam pengujian f1-score untuk menunjukkan keselarasan antara hasil pengujian akurasi klasifikasi dan f1-score.

Rata-rata f1-score dari 36 kombinasi parameter *Flower Pollination Algorithm* (FPA) terhadap f1-score pada *validation* dataset dan *actual training* dataset disajikan pada tabel 10. Tujuan utamanya adalah untuk mengukur keseimbangan antara precision dan recall, menghindari bias klasifikasi terhadap kelas mayoritas, mendeteksi overfitting, serta menentukan model terbaik secara menyeluruh (bukan hanya akurasi). Nilai F1-score tertinggi pada *validation* dataset diperoleh pada *switch probability* 0,7; 15 *neuron* pada *hidden layer*; dan 25 populasi dengan nilai f1-score *validation* = 72,312% (kombinasi parameter nomor 26, ditandai dengan warna hijau pada tabel 10 kolom rata-rata f1-score *validation* dataset (%)). Nilai f1-score tertinggi pada *actual training* dataset diperoleh pada *switch probability* 0,5; 10 *neuron* pada *hidden layer*; dan 20 populasi dengan nilai f1-score *actual training* dataset = 83,632% (kombinasi parameter nomor 4, ditandai dengan warna hijau pada tabel 10 kolom rata-rata f1-score *actual training* dataset (%)). Tingginya nilai f1-score *actual training* dataset pada kombinasi parameter nomor 4 menunjukkan bahwa kombinasi parameter tersebut kemungkinan besar mengalami overfitting, yakni terlalu menyesuaikan diri dengan pola data *training* namun kesulitan melakukan generalisasi terhadap data baru. Jika dibandingkan dengan nilai rujukannya terhadap *actual training* dan *validation* dataset, kombinasi parameter nomor 4 dikatakan overfitting dikarenakan memiliki selisih nilai 17,466% sedangkan kombinasi parameter nomor 26 memiliki potensi overfitting dengan nilai selisih 9,874%.

Secara keseluruhan kombinasi parameter yang memberikan rata-rata f1-score tertinggi pada *training* dan *validation* dataset diperoleh pada *switch probability* 0,7; 15 *neuron* pada *hidden layer*; dan 25 populasi dengan nilai rata-rata f1-score pada *validation* dan *training* sebesar 72,312% (Model nomor 26, pada tabel 10 ditandai dengan warna kuning) dapat dikatakan cukup baik. Alasan model nomor 26 dikatakan cukup baik dikarenakan model memberikan nilai selisih antara *validation* dan *training* dataset yang paling kecil diantara pembandingnya.

Rekapitulasi hasil pengujian pada tabel 11 ini membuktikan bahwa model pembelajaran dengan kombinasi parameter *switch probability* sebesar 0,7; *neuron* pada *hidden layer* dengan nilai 15; dan populasi sebanyak 25 dengan nilai rata-rata f1-score pada *actual training* dataset dan *validation* dataset sebesar 77,249% adalah yang tertinggi dari seluruh pembanding dan model pembelajaran FPNN cukup baik pada dataset penyakit akibat gigitan nyamuk.

TABEL 10
HASIL PENGUJIAN F1-SCORE 5 PERCOBAAN PADA ACTUAL TRAINING DATASET DAN VALIDATION DATASET

No	Parameter			Rata-rata F1-score validation dataset (%)	Rata-rata F1-score actual training dataset (%)	Rata-rata F1-score dari actual training dataset dan validation dataset (%)
	Switch Probability	Jumlah neuron pada Hidden Layer	Populasi			
1	0,5	5	20	65,712	81,128	73,42
2	0,5	5	25	61,324	82,278	71,801
3	0,5	5	30	59,564	80,414	69,989
4	0,5	10	20	66,166	83,632	74,899
5	0,5	10	25	65,44	82,182	73,811
6	0,5	10	30	68,038	82,562	75,3
7	0,5	15	20	59,462	81,094	70,278
8	0,5	15	25	64,686	82,598	73,642
9	0,5	15	30	59,102	81,658	70,38
10	0,6	5	20	64,462	81,648	73,055
11	0,6	5	25	61,53	82,076	71,803
12	0,6	5	30	64,262	82,022	73,142
13	0,6	10	20	60,394	81,896	71,145
14	0,6	10	25	66,222	82,522	74,372
15	0,6	10	30	60,77	82,72	71,745
16	0,6	15	20	59,612	81,636	70,624
17	0,6	15	25	69,562	82,768	76,165
18	0,6	15	30	62,086	82,592	72,339
19	0,7	5	20	62,58	81,734	72,157
20	0,7	5	25	68,156	81,404	74,78
21	0,7	5	30	67,266	82,446	74,856
22	0,7	10	20	62,784	82,378	72,581
23	0,7	10	25	55,912	82,642	69,277
24	0,7	10	30	66,574	81,944	74,259
25	0,7	15	20	65,376	81,172	73,274
26	0,7	15	25	72,312	82,186	77,249
27	0,7	15	30	60,606	82,264	71,435
28	0,8	5	20	61,918	81,782	71,85
29	0,8	5	25	64,782	82,632	73,707
30	0,8	5	30	58,604	81,822	70,213
31	0,8	10	20	62,914	81,706	72,31
32	0,8	10	25	64,514	81,648	73,081
33	0,8	10	30	56,642	81,846	69,244
34	0,8	15	20	63,938	82,652	73,295
35	0,8	15	25	69,42	81,88	75,65
36	0,8	15	30	64,028	81,802	72,915

TABEL 11
PARAMETER TERBAIK PADA PENGUJIAN BERDASARKAN F1-SCORE

Parameter			Rata-rata F1-score dari actual training dataset dan validation dataset (%)
Switch Probability	Jumlah neuron pada Hidden layer	Populasi	
0,7	15	25	77,249

C. Pengujian Parameter Model

Untuk melihat kemampuan FPNN terhadap kombinasi parameter yang dipilih dapat dilihat pada tabel 12 yang menyajikan rata-rata akurasi hasil pengujian berdasarkan variasi nilai *switch probability*, jumlah *neuron* pada *hidden layer*, dan jumlah populasi. Nilai rata-rata akurasi *actual training* dan *validation* dataset tertinggi parameter *switch probability* 0,5 dengan nilai 88,44% (ditandai dengan warna hijau pada tabel 12). Hal ini menunjukkan bahwa probabilitas perpindahan antara penyerbukan

global dan lokal pada nilai tersebut mampu memberikan keseimbangan pencarian solusi yang optimal. Akurasi *actual training* dan *validation* dataset tertinggi pada parameter jumlah *neuron* pada *hidden layer* 15 dengan nilai 88,50% (ditandai dengan warna hijau pada tabel 12). Hal ini menunjukkan bahwa peningkatan jumlah *neuron* mampu meningkatkan kemampuan jaringan dalam menangkap pola kompleks pada data. Akurasi *actual training* dan *validation* dataset tertinggi pada jumlah parameter populasi 25 dengan nilai 88,62% (ditandai dengan warna hijau pada tabel 12). Hal ini menunjukkan bahwa jumlah kandidat solusi pada ukuran populasi tersebut cukup untuk melakukan eksplorasi ruang solusi secara optimal.

Nilai rata-rata F1-score *actual training* dan *validation* dataset tertinggi parameter *switch probability* 0,7 dengan nilai 73,28% (ditandai dengan warna biru pada tabel 12). Meskipun akurasi pada 0,5 sedikit lebih tinggi, performa klasifikasi secara keseluruhan lebih optimal pada nilai 0,7 karena F1-score meningkat secara signifikan. Nilai rata-rata F1-score *actual training* dan *validation* dataset tertinggi pada parameter jumlah *neuron* pada *hidden layer* 15 dengan nilai 73,28 % (ditandai dengan warna biru pada tabel). Nilai rata-rata F1-score *actual training* dan *validation* dataset tertinggi pada parameter populasi dengan nilai 25 = 73.81% (ditandai dengan warna biru pada tabel 12). Hal ini menunjukkan bahwa populasi 25 memberikan proses pencarian solusi paling optimal pada algoritma FPA.

Nilai rata-rata akurasi dan F1-score *actual training* dan *validation* dataset tertinggi parameter *switch probability* 0,7 dengan nilai 80,85% (ditandai dengan warna kuning pada tabel 12). Nilai rata-rata akurasi dan F1-score *actual training* dan *validation* dataset tertinggi pada parameter jumlah *neuron* pada *hidden layer* 15 dengan nilai 73,10% (ditandai dengan warna kuning pada tabel 12). Nilai rata-rata akurasi dan F1-score *actual training* dan *validation* dataset tertinggi pada parameter jumlah populasi 25 dengan nilai 73,82% (ditandai dengan warna kuning pada tabel 12). Hal ini menunjukkan bahwa jumlah solusi pada ukuran populasi tersebut mampu memberikan keseimbangan antara eksplorasi ruang solusi dan efisiensi proses optimasi.

Secara keseluruhan ketika penggunaan parameter *switch probability* yang terlalu besar dapat menurunkan akurasi dan mengindikasikan proses eksplorasi menjadi kurang efektif, sedangkan pada F1-score terlihat bahwa probabilitas perpindahan antara proses penyerbukan global dan lokal algoritma FPA berada pada kondisi paling seimbang dan meningkatkan kemampuan model dalam mengklasifikasikan setiap kelas secara lebih merata. Nilai parameter yang tinggi atau rendah menyebabkan model cenderung kehilangan keseimbangan antara proses eksplorasi dan eksploitasi, sehingga meskipun prediksi umum masih cukup baik, kemampuan model dalam mempertahankan precision dan recall menjadi menurun. Peningkatan jumlah *neuron* pada *hidden layer* mampu meningkatkan kemampuan jaringan dalam menangkap pola kompleks pada data. Peningkatan ini masih berada pada kondisi optimal sehingga tidak menimbulkan overfitting dan dapat dikatakan bahwa penggunaan 15 *neuron* pada *hidden layer* dapat memberikan representasi fitur yang paling efektif. Nilai populasi yang tinggi atau rendah menunjukkan jumlah kandidat solusi pada ukuran populasi. Ukuran populasi berperan penting dalam menentukan kemampuan algoritma dalam melakukan pencarian solusi optimal selama proses optimasi parameter berlangsung. Populasi yang kecil menyebabkan ruang pencarian solusi menjadi terbatas sehingga algoritma kurang mampu mengeksplorasi berbagai kemungkinan kombinasi parameter, sehingga menghasilkan performa model kurang optimal. Sebaliknya, populasi yang terlalu besar memang meningkatkan keberagaman solusi yang dieksplorasi, namun juga dapat menyebabkan proses pencarian menjadi kurang efisien karena meningkatnya kompleksitas komputasi dan penambahan jumlah populasi tidak selalu meningkatkan performa model secara signifikan, karena solusi yang dihasilkan cenderung memiliki kualitas yang serupa.

TABEL 12
PENGUJIAN PERFORMA MODEL BERDASARKAN VARIASI PARAMETER

Parameter		Rata-rata akurasi <i>actual training</i> dan <i>validation</i> dataset (%)	Rata-rata F1-score <i>actual training</i> dan <i>validation</i> dataset (%)	Rata-rata akurasi dan F1-score <i>actual training</i> dan <i>validation</i> dataset (%)
Switch Probability	0,5	88.44	72.67	80.55
	0,6	88.42	72.71	80.57
	0,7	88.43	73.28	80.86
	0,8	88.36	72.47	80.42
Jumlah neuron pada Hidden layer	5	88.23	72.61	80.42
	10	88.48	72.67	80.57
	15	88.50	73.10	80.80
	20	88.29	72.41	80.35
Populasi	25	88.62	73.82	81.22
	30	88.30	72.15	80.23

IV. SIMPULAN

Berdasarkan hasil pengujian dan analisis yang telah dilakukan bahwa model FPNN (*Flower Pollination Neural Network*) menunjukkan performa klasifikasi yang baik terhadap dataset biner penyakit akibat gigitan nyamuk. Evaluasi yang dilakukan menggunakan *10-fold cross validation* sebanyak lima kali percobaan dengan kombinasi parameter yang berbeda, mencakup *switch probability*, jumlah *neuron* pada *hidden layer*, dan populasi. Seluruh percobaan menggunakan pembagian data yang sama pada setiap fold, sehingga seluruh data berperan sebagai data latih maupun data uji secara bergantian.

Hasil evaluasi berdasarkan akurasi menunjukkan bahwa kombinasi parameter nomor 26 (*switch probability* = 0,7; 15 *neuron* pada *hidden layer*; dan 25 populasi) dengan hasil akurasi 88,5% dikatakan baik, meskipun tidak lebih tinggi dari kombinasi parameter nomor 4. Hal ini didukung dengan selisih nilai pada kombinasi parameter nomor 26 sebesar 4,2% yang menunjukkan kemampuan generalisasi yang baik pada data yang belum pernah dipelajari dibandingkan kombinasi parameter nomor 4 yang memiliki selisih 4,91%. Selain itu, kombinasi parameter nomor 26 menunjukkan performa yang stabil pada *validation dataset*.

Sementara itu, evaluasi F1-score menggunakan kombinasi parameter yang sama menghasilkan nilai rata-rata pada *validation dataset* sebesar 72,312% dan *actual training dataset* sebesar 82,186%. Selisih sebesar 9,874% menunjukkan bahwa model dapat dikatakan cukup baik. Jika dibandingkan dengan kombinasi parameter lainnya, model ini masih menunjukkan performa yang baik antara data *training* dan *validation*. Hal ini mengindikasikan bahwa meskipun terdapat kecenderungan model menyesuaikan diri terhadap data *training*, kemampuan generalisasi terhadap data baru tetap cukup baik. Oleh karena itu, kombinasi parameter ini merupakan model terbaik karena memberikan keseimbangan yang cukup baik antara kemampuan mengenali pola pelatihan dan memprediksi data yang belum pernah dipelajari.

Secara keseluruhan, model FPNN menunjukkan performa klasifikasi yang baik pada *validation dataset* dalam hal akurasi dan cukup baik pada F1-score. Penggunaan parameter *switch probability* sebesar 0,7; 15 *neuron* pada *hidden layer*; dan 25 populasi merupakan parameter terbaik diantara pembandingnya dengan hasil akurasi mencapai 86,4% dan F1-score mencapai 72,312%. Kombinasi parameter tersebut dapat digunakan untuk mengidentifikasi data lokal penyakit akibat gigitan nyamuk secara efektif, serta menunjukkan bahwa model FPNN mampu mempelajari pola karakteristik dataset lokal dengan tingkat generalisasi yang baik. Pada penelitian selanjutnya dapat mempertimbangkan penambahan teknik penyeimbangan kelas, penambahan dataset, serta melakukan perbandingan kinerja model dengan algoritma metaheuristik lainnya guna memperoleh performa klasifikasi yang lebih optimal.

DAFTAR PUSTAKA

- [1] G. Setiawan and G. S. Budi, "Implementasi Metode Forward Chaining Pada Sistem Pakar Untuk Penyakit DBD," *Dike*, vol. 1, no. 2, pp. 44–48, 2023.
- [2] R. Rafdinal, D. Lestari, A. M. Ashari, R. K. Apindiati, and A. B. Aritonang, "Usaha Pencegahan Penularan Penyakit Malaria melalui Sosialisasi Bersih Lingkungan Ekowisata Mangrove Kuala Mempawah," *Lambung Inov. J. Pengabd. Kpd. Masy.*, vol. 7, no. 4, pp. 670–675, 2022.
- [3] B. P. Statistik, "Jumlah Kasus Penyakit Menurut Provinsi dan Jenis Penyakit." [Online]. Available: <https://www.bps.go.id/id/statistics-table/3/YTA1Q1ptRmhUMEpXWTBsQmQyZzBjVzgwUzB4Vp6MDkzMw==/kasus-penyakit-menurut-provinsi-dan-jenis-penyakit--2018.html?year=2018>
- [4] Y. Yulisman, "Sistem Pakar Mendiagnosa Penyakit Demam Berdarah Dengue (DBD) Menggunakan Metode Forward Chaining Berbasis Web," *J. Ilmu Komput.*, vol. 8, no. 2, pp. 34–46, 2019.
- [5] F. N. Lobo, M. S. P. P. Bere, and J. E. Lauwoie, "Pengelolaan Sampah di Pasar Kota Kupang," *J. Ilm. Kaji. Multidisipliner*, vol. 8, no. 7, pp. 373–378, 2024.
- [6] Ombudsman Nusa Tenggara Timur, "Bahas Masalah Sampah, Ombudsman NTT Temui Dinas Kebersihan Kota Kupang," Ombudsman Republik Indonesia.
- [7] I. Hau and D. Djohan, "Implementasi Kebijakan Penanganan Sampah di Kota Kupang Provinsi Nusa Tenggara Timur," *Eprints.Ipdn.Ac.Id*, no. Edward III, 2024.
- [8] L. P. Sayrani and L. M. Tamunu, "Kewargaan dan Kolaborasi Pemecahan Masalah Publik : Studi Isu Sampah di Kota Kupang," *Timorese J. Public Heal.*, vol. 2, no. 1, pp. 1–13, 2020.
- [9] Dinas Kesehatan Kota Kupang, "Profil Kesehatan," no. 0380, 2021, [Online]. Available: <https://ppid.dinkes-kotakupang.info/informasi-publik/informasi-berkala/profil-kesehatan/profil-kesehatan-kota-kupang-tahun-2021.html>
- [10] M. H. B. A. Yazid, M. S. Talib, and M. H. Satria, "Flower pollination neural network for heart disease classification," in *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, 2019, p. 12072.
- [11] A. P. Kusuma and A. Sugiarto, "Perancangan Dan Implementasi Sistem Pakar Diagnosis Pertolongan Pertama Penyakit Akibat Gigitan Nyamuk Menggunakan Metode Certainty Factor Berbasis Android," *J. Tek.*, vol. 12, no. 1, pp. 27–32, 2020.
- [12] B. Pratama, "Sistem Pakar Mendiagnosa Penyakit Demam Berdarah Akibat Virus Nyamuk Aedes Aegypti Dengan Menggunakan Metode Certainty Factor," *Excell. Midwifery J.*, vol. 2, no. 2, pp. 68–73, 2019.
- [13] A. L. Ghazali, M. I. Prakoso, and A. A. Muin, "Penerapan Sistem Pakar Diagnosa Demam Berdarah Dengue Menggunakan Certainty Factor Methods," *J. INSYPRO (Information Syst. Process.)*, vol. 2, no. 2, 2017.
- [14] E. C. Okafor and C. C. Osuagwu, "Issues in Structuring the Knowledge-base of Expert Systems," *Electron. J. Knowl. Manag.*, vol. 5, no. 3, pp. 314–323, 2007.
- [15] H. Listiyono, "Merancang dan Membuat Sistem Pakar," *Dinamik*, vol. 13, no. 2, 2008.
- [16] N. R. Sari and Y. Mar'atullatifah, "Penerapan Multilayer Perceptron untuk Identifikasi Kanker Payudara," *J. Cakrawala Ilm.*, vol. 2, no. 8, pp. 3261–3268, 2023.
- [17] N. K. S. Julyantari, "Perancangan Prediksi Keputusan Medis Untuk Penyakit Demam Berdarah Dengue Dengan Jaringan Syaraf Tiruan," in *Konferensi Nasional Sistem dan Informatika 2015*, STMIK STIKOM Bali, 2015.

- [18] C. D. Suhendra and R. Wardoyo, "Penentuan arsitektur jaringan syaraf tiruan backpropagation (bobot awal dan bias awal) menggunakan algoritma genetika," *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 9, no. 1, pp. 77–88, 2015.
- [19] A. Sato and K. Yamada, "Generalized learning vector quantization," *Adv. Neural Inf. Process. Syst.*, vol. 8, 1995.
- [20] M. Alweshah, M. A. Qadoura, A. I. Hammouri, M. S. Azmi, and S. AlKhalailah, "Flower Pollination Algorithm for Solving Classification Problems," *Int. J. Adv. Soft Comput. its Appl.*, vol. 12, no. 1, pp. 15–34, 2020.
- [21] B. Santosa, *Pengantar Metaheuristik: Implementasi dengan Matlab*, vol. 1. ITS Tekno Sains, 2017.
- [22] X. S. Yang, "Flower pollination algorithm for global optimization," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7445 LNCS, pp. 240–249, 2012.
- [23] Y. T. Polly, S. Hartati, and B. Sumiarto, "Modified Flower Pollination Algorithm for Disease Identification in Swine.," *Int. J. Intell. Eng. Syst.*, vol. 14, no. 6, 2021.
- [24] Y. T. Polly, Sri Hartati, Suprpto, and B. Sumiarto, "A Novel Approach to Multi-Layer-Perceptron Training using Quadratic Interpolation Flower Pollination Neural Network on Non-Binary Datasets," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 6, pp. 497–504, 2023.
- [25] Y. Yohannes, S. Devella, and K. Arianto, "Deteksi Penyakit Malaria Menggunakan Convolutional Neural Network Berbasis Saliency," *JUITA J. Inform.*, vol. 8, no. 1, pp. 37–44, 2020.
- [26] F. Tawakal and A. Azkiya, "Diagnosa Penyakit Demam Berdarah Dengue (DBD) menggunakan Metode Learning Vector Quantization (LVQ)," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 4, no. 3, pp. 193–201, 2020.
- [27] R. D. Adyati, Y. N. Nasution, and S. Wahyuningsih, "Klasifikasi probabilistic neural network (pnn) pada data diagnosa penyakit demam berdarah dengue (dbd) tahun 2018," in *Prosiding Seminar Nasional Matematika dan Statistika*, 2019, pp. 15–21.
- [28] R. Parveen *et al.*, "Prediction of malaria using artificial neural network," *Int J Comput Sci Netw Secur*, vol. 17, no. 12, pp. 79–86, 2017.
- [29] Y. T. Polly, S. Hartati, Suprpto, and B. Sumiarto, "Modified Flower Pollination Algorithm For Disease Identification In Swine," *Int. J. Intell. Eng. Syst.*, vol. 14, no. 6, pp. 616–628, 2021.
- [30] Y. N. U. R. Fuadah, I. D. Ubaidullah, N. U. R. Ibrahim, F. F. Taliningsih, N. K. SY, and M. A. Pramuditho, "Optimasi convolutional neural network dan k-fold cross validation pada sistem klasifikasi glaukoma," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 3, p. 728, 2022.
- [31] M. M. Baharuddin, H. Azis, and T. Hasanuddin, "Analisis Performa Metode K-Nearest Neighbor Untuk Identifikasi Jenis Kaca," *Ilk. J. Ilm.*, vol. 11, no. 3, pp. 269–274, 2019.
- [32] D. Cahyanti, A. Rahmayani, and S. A. Husniar, "Analisis performa metode Knn pada Dataset pasien pengidap Kanker Payudara," *Indones. J. Data Sci.*, vol. 1, no. 2, pp. 39–43, 2020.
- [33] A. M. H. Sorisi, "Transmisi transovarial virus dengue pada nyamuk aedes Spp.," *J. Biomedik*, vol. 5, no. 1, 2013.
- [34] M. E. Y. G. Effruan, "Perilaku Masyarakat Dalam Upaya Pencegahan Penyakit Malaria Di Wilayah Kerja Puskesmas Un Kota Tual," Universitas Hasanuddin, 2013. [Online]. Available: <https://repository.unhas.ac.id/id/eprint/9165/2/meyguysnef-1700-1-13-meyg-n 1-2.pdf>