



Model Deep Learning Berbasis Multilayer Perceptron untuk Identifikasi Demam Berdarah Dengue dan Tifus

Nurhadi Nurhadi^{1,*}, Sarjon Defit², Gunadi Widi Nurcahyo²

¹Program Studi Teknik Informatika, Institut Teknologi dan Bisnis Riau Pesisir, Dumai, Indonesia

²Fakultas Ilmu Komputer, Teknik Informatika, Universitas Putra Indonesia YPTK Padang, Padang, Indonesia

Email: ^{1,*}flinkdumai@gmail.com, ²sarjon_defit@upiypk.ac.id, ³gunadiwidi@yahoo.co.id

Email Penulis Korespondensi: flinkdumai@gmail.com

Abstrak—Demam Berdarah Dengue (DBD) dan Tifus/*Typhoid* merupakan dua penyakit menular yang sering ditemukan di daerah tropis. Di Indonesia, data menunjukkan bahwa kasus DBD dan Tifus cukup tinggi, sehingga diperlukan sistem yang mampu membantu dokter dalam membuat keputusan yang lebih akurat dan cepat berdasarkan hasil cek darah. Berdasarkan penjelasan sebelumnya maka, penelitian ini bertujuan menerapkan *Deep Learning* metode *Multilayer Perceptron* (MLP) untuk dapat mengidentifikasi penyakit demam berdarah dan tifus. Penelitian ini menggunakan pendekatan *Multilayer Perceptron* berbasis Pembelajaran Mendalam untuk klasifikasi akurat kasus Demam Dengue, Demam *Typhoid*, dan kasus Normal menggunakan parameter darah klinis dan gejala terpilih. Metodologi ini terdiri dari beberapa tahap: akuisisi dataset, prapemrosesan, desain arsitektur model, pelatihan, dan evaluasi. Dataset diambil dari Data rekam medis di RSUD Kota Dumai tahun 2023 sampai 2024 sebanyak 379 data pasien yang digunakan untuk mengidentifikasi penyakit DBD dan Tifus menggunakan 7 parameter klinis sebagai input utama yang diperoleh dari hasil pemeriksaan laboratorium dan gejala klinis pasien: jumlah *Hemoglobin*, *Leukosit*, *Trombosit*, jumlah *Hematokrit*, Sakit Kepala, Nyeri Perut, dan diare. Berdasarkan hasil yang diperoleh, aplikasi menunjukkan kinerja terbaik dalam mengklasifikasikan penyakit DBD, yang ditunjukkan melalui capaian metrik evaluasi model sebagai berikut. Hasil pengujian mengindikasikan bahwa peningkatan jumlah data uji berbanding lurus dengan persentase keberhasilan klasifikasi yang dicapai sistem. Berdasarkan hasil pengujian dengan data latih 70%, data uji sebanyak 20%, dan data validasi sebanyak 10%, sistem menunjukkan performa yang sangat baik dengan akurasi keseluruhan sebesar: 98,68% (Accuracy = 0.9868), yang mengindikasikan tingkat keberhasilan tinggi dalam melakukan klasifikasi untuk ketiga kelas, yaitu Normal, DBD, dan Tifus.

Kata Kunci: DBD; Tifus; Deep Learning; MLP; Python, ANN

Abstract—Dengue Hemorrhagic Fever (DHF) and Typhus/Typhoid are two infectious diseases often found in tropical areas. In Indonesia, data shows that cases of DHF and typhoid are quite high, so a system is needed that can help doctors make faster and more accurate decisions based on blood test results. Based on the previous explanation, this study aims to apply the Deep Learning Multilayer Perceptron (MLP) method to be able to identify dengue fever and typhus. This study uses a Deep Learning-based Multilayer Perceptron approach for accurate classification of Dengue Fever, Typhoid Fever, and Normal cases using clinical blood parameters and selected symptoms. This methodology consists of several stages: dataset acquisition, preprocessing, model architecture design, training, and evaluation. The dataset was taken from Dumai City Hospital medical record data from 2023 to 2024, totaling 379 patient data used to identify Dengue Fever and Typhus using 7 clinical parameters as the main input obtained from laboratory examination results and patient clinical symptoms: Hemoglobin, Leukocyte, Platelet count, Hematocrit level, Headache, Abdominal pain, and diarrhea. Based on the results obtained, the application showed the best performance in classifying Dengue Fever, which is shown through the achievement of the model evaluation metrics as follows. The test results indicate that an increase in the amount of test data is directly proportional to the percentage of classification success achieved by the system. Based on the test results with 10% validation data, 70% training data, and 20% test data, the system showed very good performance with an overall accuracy of: 98.68% (Accuracy = 0.9868), which indicates a high level of success in classifying for the three classes, namely Normal, Dengue Fever, and Typhus.

Keywords: Dengue Fever; Typhus; Deep Learning; MLP; Python, ANN

1. PENDAHULUAN

Demam berdarah menyebabkan sekitar 10.000 kematian dan 100 juta infeksi simptomatik setiap tahunnya di seluruh dunia, sehingga menjadikannya masalah kesehatan masyarakat yang signifikan [1], sedangkan Setiap tahunnya, demam tifoid diperkirakan menyebabkan 11 hingga 18 juta infeksi dan 100.000 hingga 200.000 kematian [2]. Demam Berdarah *Dengue* (DBD) dan Tifus/*Typhoid* merupakan dua penyakit menular yang sering ditemukan di daerah tropis, termasuk Indonesia. Kedua penyakit ini sering kali menimbulkan tanda-tanda yang serupa, antara lain demam tinggi, sakit kepala, serta nyeri otot, yang membuat proses identifikasi menjadi menantang. Metode konvensional untuk mengidentifikasi penyakit DBD dan tifus melibatkan interpretasi manual terhadap hasil laboratorium, yang tidak hanya memerlukan waktu, tetapi juga rentan terhadap kesalahan manusia. Dengan demikian, dibutuhkan suatu pendekatan inovatif yang mampu dalam mempercepat proses identifikasi dengan tingkat akurasi yang lebih tinggi [3], [4]. DBD adalah penyakit yang ditularkan oleh nyamuk *Aedes Aegypti* dan *Aedes Albopictus*, yang biasa ditemukan di daerah tropis dan subtropis seperti Indonesia hingga bagian utara Australia. Nyamuk *Aedes* biasanya menggigit manusia pada siang hari. Terdapat 4 jenis virus *dengue*, yaitu; 1). virus 1 (DENV-1); 2.). virus 2 (DENV-2), 3); virus 3 (DENV-3); 4). virus 4 (DENV-4), namun di Indonesia, tipe *dengue* 3 lebih dominan.

Seiring dengan perkembangan teknologi, *Machine Learning* dan *Deep Learning* telah menjadi salah satu solusi yang efektif dalam mengatasi berbagai masalah klasifikasi dan identifikasi dalam bidang kesehatan [5], [6], [7]. *Deep Learning* metode *Multilayer Perceptron* (MLP) adalah metode pembelajaran mesin dasar yang kuat dan fleksibel, cocok untuk berbagai tugas pembelajaran mesin, terutama untuk data yang terstruktur dan kompleks, salah satu penggunaannya di bidang medis untuk proses data klinis secara simultan [8], [9], [10]. *Deep Learning* dengan metode *Multilayer*



Perceptron (MLP) dapat menjadi solusi yang menjanjikan untuk mengidentifikasi penyakit DBD dan Tifus/*Typhoid*. Selain itu, dengan implementasi menggunakan bahasa pemrograman *Python*, proses integrasi dan pengembangan sistem dapat dilakukan dengan lebih efisien dan fleksibel [11].

Seiring dengan perkembangan teknologi, *Machine Learning* telah menjadi salah satu solusi yang efektif dalam mengatasi berbagai masalah klasifikasi dan identifikasi dalam bidang kesehatan [5], [6], [7]. *Deep Learning* metode *Multilayer Perceptron* (MLP) adalah metode pembelajaran mesin dasar yang kuat dan fleksibel, cocok untuk berbagai tugas pembelajaran mesin [12], terutama untuk data yang terstruktur dan kompleks, salah satu penggunaannya di bidang medis untuk proses data klinis secara simultan [8], [9], [10]. *Deep Learning* dengan metode *Multilayer Perceptron* (MLP) dapat menjadi solusi yang menjanjikan untuk mengidentifikasi penyakit DBD dan Tifus/*Typhoid*. Selain itu, dengan implementasi menggunakan bahasa pemrograman *Python*, proses integrasi dan pengembangan sistem dapat dilakukan dengan lebih efisien dan fleksibel [13], [11], [14]. Riwayat penelitian terdahulu menghasilkan untuk Prediksi wabah demam berdarah menggunakan NN MLP dan *Decision Tree* menghasilkan teknik terbaik untuk prediksi Dengue yang mencapai akurasi 97.3%. Riwayat penelitian terdahulu menghasilkan untuk Prediksi wabah demam berdarah menggunakan NN MLP dan *decision tree* menghasilkan teknik terbaik untuk prediksi Dengue yang mencapai akurasi 97.3%, sedangkan *Decision Tree* dapat dipertimbangkan sebagai opsi kedua [15]. Salah satu metode yang menonjol adalah *Multilayer Perceptron* (MLP), bagian dari metode *Deep Learning*, berbasis jaringan saraf tiruan yang terdiri dari beberapa lapisan tersembunyi (*hidden layers*) dan mampu menangani data kompleks secara simultan [5], [9], [16]. MLP memiliki kemampuan untuk menganalisis data medis dalam skala besar dan mendeteksi pola yang sulit dikenali secara manual [17], [18], [19]. Dalam MLP, proses pelatihan jaringan menggunakan algoritma *Backpropagation*, yang bertujuan meminimalkan kesalahan prediksi melalui penyebaran balik dari error [17], [15], [20].

Selain menghasilkan model identifikasi yang lebih akurat, penelitian ini juga diharapkan mampu memberikan sebuah kontribusi di dalam pengembangan aplikasi dengan menggunakan metode *Deep Learning* di bidang kesehatan, serta menjadi referensi bagi penelitian serupa di masa mendatang [21], [22], [23]. Dengan adanya sistem yang lebih canggih dan teruji, diharapkan identifikasi penyakit DBD dan Tifus/*Typhoid* dapat dilakukan dengan lebih cepat dan akurat, sehingga dapat membantu dalam pengambilan keputusan medis yang lebih tepat. Sistem yang lebih canggih dan teruji, diharapkan identifikasi penyakit DBD dan Tifus/*Typhoid* dapat dilakukan dengan lebih cepat dan akurat, sehingga dapat membantu dalam pengambilan keputusan medis yang lebih tepat. Keseluruhan penelitian ini juga akan mampu menyajikan sebuah model identifikasi yang efektif dan efisien yang bertujuan untuk mengembangkan dan mengimplementasikan model *Deep Learning* metode *Multilayer Perceptron* (MLP) dalam bentuk aplikasi yang mampu mengidentifikasi penyakit DBD atau Tifus/*Typhoid* berdasarkan parameter hasil cek darah seperti; *hemoglobin*, *leukosit*, *trombosit*, *hematokrit*, sakit kepala, nyeri perut, dan diare. Data yang digunakan berasal dari hasil laboratorium dan rekam medis RSUD Kota Dumai.

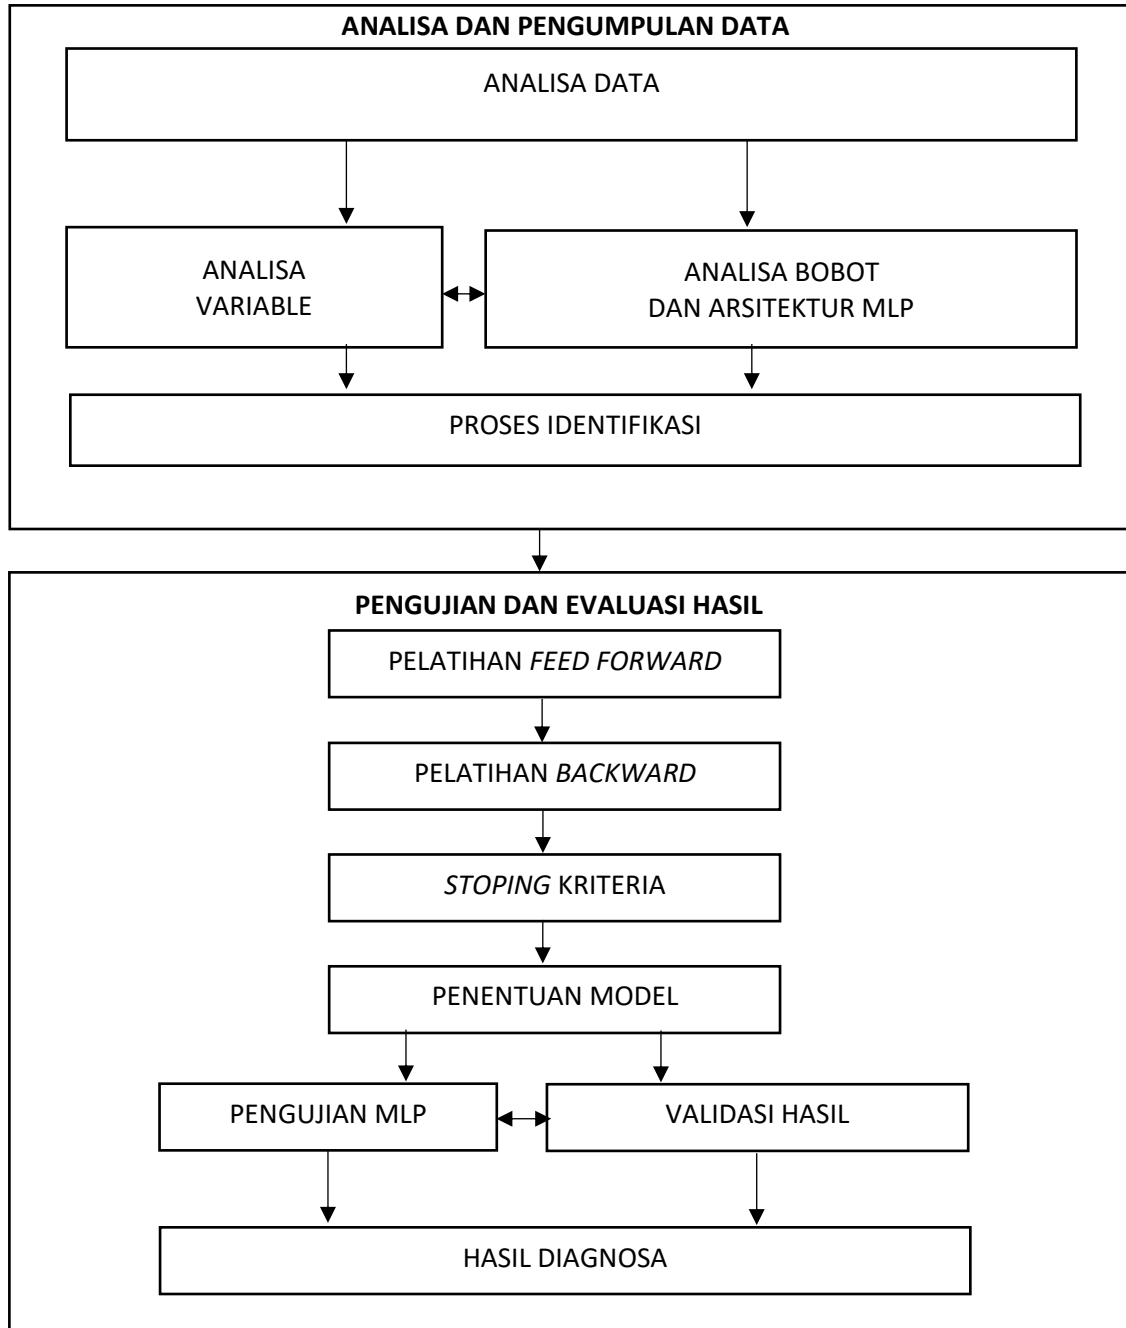
2. METODOLOGI PENELITIAN

Metodologi penelitian ini dirancang secara sistematis untuk memastikan setiap langkah menghasilkan keluaran yang akurat dan dapat dipertanggungjawabkan. Proses dimulai dari analisa dan pengumpulan data, di mana data klinis dianalisis secara mendalam untuk mengidentifikasi variabel penting, sekaligus merancang bobot dan arsitektur *Multilayer Perceptron* (MLP) yang optimal. Selanjutnya, model dilatih melalui tahapan *feed forward* dan *backward* hingga memenuhi kriteria penghentian yang telah ditetapkan, guna mendapatkan model terbaik. Tahap pengujian dan evaluasi hasil dilakukan dengan membandingkan kinerja model pada data uji dan data validasi, sehingga menghasilkan diagnosis yang cepat, tepat, dan berpotensi membantu tenaga medis dalam pengambilan keputusan. Pendekatan ini tidak hanya mengedepankan akurasi, tetapi juga efisiensi dalam penerapan teknologi kecerdasan buatan di bidang kesehatan.

Pada tahap pelatihan, mekanisme *feed forward* digunakan untuk menghasilkan keluaran awal berdasarkan bobot yang telah ditetapkan, kemudian dilanjutkan dengan proses *backpropagation* untuk melakukan pembaruan bobot melalui perhitungan *error* hingga mencapai tingkat kesalahan minimum. Proses ini dilaksanakan secara iteratif sesuai dengan kriteria penghentian (*stopping criteria*) yang telah ditentukan, sehingga model mampu menyesuaikan bobot antar neuron secara optimal. Setelah model terbaik diperoleh, dilakukan tahap pengujian dan validasi guna mengevaluasi akurasi serta kemampuan generalisasi model terhadap data baru. Evaluasi ini tidak hanya menekankan pada ketepatan hasil diagnosis, tetapi juga mempertimbangkan efisiensi komputasi agar model dapat diterapkan secara praktis pada lingkungan nyata. Dengan demikian, metodologi penelitian ini diharapkan mampu menghasilkan sistem berbasis *Multilayer Perceptron* (MLP) yang dapat memberikan diagnosis secara cepat, akurat, dan andal, serta berfungsi sebagai alat bantu bagi tenaga medis dalam proses pengambilan keputusan, khususnya dalam upaya deteksi dini dan peningkatan kualitas layanan kesehatan. Metode penelitian pada Gambar 1 menggambarkan alur sistematis mulai dari analisis dan pengumpulan data, perancangan arsitektur *Multilayer Perceptron* (MLP), hingga tahap pelatihan dan evaluasi model. Setiap langkah dilakukan secara berurutan, mulai dari identifikasi variabel, proses pelatihan dengan mekanisme *feed forward* dan *backward propagation*, penentuan model terbaik, hingga pengujian dan validasi hasil. Rangkaian proses ini dirancang untuk menghasilkan diagnosis yang akurat dan dapat dipertanggungjawabkan secara ilmiah. Sebelum memasuki tahapan teknis penelitian, diperlukan suatu metode yang sistematis agar alur kerja penelitian dapat dijelaskan dengan jelas. Metode penelitian yang digunakan dalam studi ini digambarkan secara skematis untuk menunjukkan urutan proses mulai dari



pengumpulan data hingga menghasilkan diagnosis. Adapun alur metode penelitian yang digunakan dapat dilihat pada Gambar 1.



Gambar 1. Metode Penelitian

Pada Bagian Pertama Gambar 1 memperlihatkan tahapan penelitian yang terbagi menjadi dua bagian besar, yaitu tahap analisis dan pengumpulan data serta tahap pengujian dan evaluasi hasil. Pada bagian pertama, proses dimulai dengan analisis data yang bertujuan untuk memahami karakteristik data yang digunakan. Selanjutnya dilakukan analisis variabel serta perancangan bobot dan arsitektur Multilayer Perceptron (MLP) sebagai dasar pembentukan model. Hasil dari tahap ini menghasilkan proses identifikasi yang menjadi pondasi awal dalam membangun sistem. Pada bagian kedua, yaitu tahap pengujian dan evaluasi hasil, dilakukan proses pelatihan model yang terdiri dari feed forward dan backward propagation hingga mencapai kriteria penghentian (stopping criteria). Setelah itu, model yang terbentuk ditentukan dan diuji melalui pengujian MLP serta divalidasi untuk memastikan keakuratan dan konsistensi hasil. Keseluruhan rangkaian pada Gambar 1 kemudian diakhiri dengan keluaran berupa hasil diagnosis, yang menjadi tujuan utama dari penelitian ini.

2.1 Analisa dan Pengumpulan Data

Analisa dan Pengumpulan Data merupakan tahap awal dalam metodologi penelitian yang bertujuan memastikan data yang digunakan benar-benar relevan, berkualitas, dan sesuai dengan kebutuhan model. Proses ini diawali dengan analisa



data, yaitu pemeriksaan awal terhadap dataset untuk memahami struktur, jenis data, serta distribusi nilainya. Langkah ini mencakup pembersihan data (*data cleaning*) untuk menghapus atau memperbaiki data yang hilang, tidak konsisten, atau mengandung kesalahan, sehingga dapat mengurangi risiko bias pada hasil pelatihan model. Selanjutnya dilakukan analisa variabel, yaitu pemilihan parameter-parameter klinis yang memiliki pengaruh signifikan terhadap identifikasi penyakit. Pada penelitian ini, tujuh parameter dipilih sebagai input utama, meliputi: *hemoglobin*, *leukosit*, *trombosit*, *hematokrit*, sakit kepala, nyeri perut, dan diare. Parameter tersebut dipilih berdasarkan kajian medis dan literatur yang relevan, serta pertimbangan dari praktisi kesehatan. Tahap berikutnya adalah analisa bobot dan arsitektur MLP, yang bertujuan merancang struktur jaringan saraf tiruan yang optimal, termasuk penentuan jumlah lapisan tersembunyi (*hidden layers*), jumlah neuron pada setiap lapisan, serta fungsi aktivasi yang digunakan. Perancangan ini disesuaikan dengan kompleksitas data dan tujuan penelitian agar proses pelatihan dapat menghasilkan model dengan akurasi tinggi. Adapun dataset penelitian dalam identifikasi penyakit DBD atau Tifus disajikan pada Tabel 1.

Tabel 1. Dataset Pasien Berdasarkan Parameter Klinis dan Identifikasi

No	Hemoglobin	Leukosit	Trombosit	Hematokrit	Sakit Kepala	Nyeri Perut	Diare	Identifikasi
1	13.5	4500	150000	41	Ya	Tidak	Tidak	Normal
2	12.2	3900	110000	38	Ya	Ya	Tidak	DBD
3	11.8	5600	180000	42	Tidak	Ya	Ya	Tifus
...
377	14.5	2450	56000	71	Ya	Ya	Tidak	DBD
378	10.8	1200	195000	27	Ya	Ya	Ya	Tifus
379	10.7	1000	200000	26	Tidak	Ya	Ya	Tifus

Tabel 1 menampilkan data pasien yang digunakan dalam penelitian, terdiri dari tujuh parameter klinis utama dan satu kolom diagnosis sebagai keluaran (*output*). Parameter tersebut mencakup jumlah *hemoglobin*, jumlah *leukosit*, jumlah *trombosit*, jumlah *hematokrit*, serta tiga gejala klinis seperti; sakit kepala, nyeri perut, dan diare yang dicatat dalam kategori “Ya” atau “Tidak”. Contoh data ini menggambarkan variasi kondisi pasien mulai dari Normal, Demam Berdarah Dengue (DBD), hingga Tifus, dan berfungsi sebagai representasi awal dataset untuk pelatihan dan pengujian model *Multilayer Perceptron* (MLP).

2.2 Pengujian Dan Evaluasi Hasil

Pengujian dan Evaluasi Hasil merupakan tahap penting untuk memastikan bahwa model *Multilayer Perceptron* (MLP) yang dibangun mampu melakukan klasifikasi secara akurat dan konsisten, baik pada data uji maupun data validasi. Pada tahap ini, proses diawali dengan pelatihan *feed forward*, di mana data masukan dipropagasi maju melalui lapisan-lapisan jaringan hingga menghasilkan *output* prediksi. Hasil prediksi tersebut kemudian dibandingkan dengan nilai target sebenarnya untuk menghitung tingkat kesalahan (*error*). Kesalahan yang diperoleh digunakan pada tahap pelatihan *backward* (*backpropagation*), di mana bobot dan bias jaringan diperbarui dengan tujuan meminimalkan *error*. Perubahan bobot dilakukan menggunakan metode *Gradient Descent* dengan formula [24]:

$$W_{new} = W_{old} - n \frac{\partial E}{\partial w} \quad (1)$$

W_{new} merupakan bobot baru yang dihasilkan setelah proses pembelajaran, sedangkan W_{old} adalah bobot lama sebelum dilakukan pembaruan. Proses perubahan bobot ini dipengaruhi oleh η (*eta*) yang dikenal sebagai *learning rate*, yaitu parameter yang mengatur seberapa besar langkah perubahan bobot dilakukan pada setiap iterasi pembelajaran. Selain itu, pembaruan bobot juga mempertimbangkan nilai E , yaitu fungsi *error*, yang menunjukkan seberapa jauh hasil prediksi model berbeda dari nilai target sebenarnya. Dengan demikian, kombinasi antara bobot lama, tingkat pembelajaran, dan nilai *error* menjadi dasar dalam menentukan bobot baru yang lebih optimal, sehingga kinerja jaringan syaraf tiruan semakin meningkat dalam menghasilkan prediksi yang akurat. Proses ini dikendalikan oleh *stopping criteria*, misalnya jumlah *epoch* maksimum atau *error* yang telah mencapai nilai minimum tertentu. Setelah pelatihan selesai, dilakukan penentuan model terbaik berdasarkan performa pada data pelatihan. Model terpilih kemudian diuji pada data uji melalui pengujian MLP dan divalidasi pada data validasi untuk mengukur kemampuan generalisasi. Kinerja model dievaluasi menggunakan *Confusion Matrix* dan dihitung metrik-metrik tersaji pada formula 2-5 [25]:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$



TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*) adalah jumlah prediksi benar dan salah pada masing-masing kategori. Hasil akhir dari tahap ini adalah diagnosa penyakit yang dapat mengklasifikasikan pasien ke dalam kategori Normal, Demam Berdarah Dengue (DBD), atau Tifus/*Typhoid* dengan tingkat akurasi tinggi. Evaluasi ini tidak hanya menilai ketepatan model, tetapi juga menjadi dasar untuk optimasi lebih lanjut apabila diperlukan.

3. HASIL DAN PEMBAHASAN

Pada Hasil dan Pembahasan memperlihatkan temuan utama dari implementasi dan pengujian model *Multilayer Perceptron* (MLP), meliputi kinerja klasifikasi pada data uji dan validasi. Hasil pengujian ditampilkan dalam bentuk metrik evaluasi seperti; *accuracy*, *precision*, *recall*, dan *F1-score*, yang diperoleh dari *Confusion Matrixs*. Pembahasan difokuskan pada analisis faktor yang memengaruhi performa model, perbandingan dengan metode konvensional, serta interpretasi hasil terhadap tujuan penelitian. Bagian ini menegaskan bahwa model mampu memberikan diagnosis cepat dan akurat untuk membedakan kondisi Normal, Demam Berdarah Dengue (DBD), dan Tifus/*Typhoid*. Setelah proses pelatihan dan validasi, model *Multilayer Perceptron* (MLP) diuji menggunakan data uji untuk mengukur kinerjanya dalam mengklasifikasikan kondisi pasien. Evaluasi dilakukan dengan menghitung empat metrik utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, guna memperoleh gambaran menyeluruh mengenai tingkat ketepatan, keandalan, dan konsistensi prediksi model. Untuk mengetahui efektivitas sistem dalam melakukan identifikasi penyakit, dilakukan pengujian terhadap data pasien yang berisi parameter laboratorium serta gejala klinis. Adapun hasil pengujian identifikasi penyakit DBD/Tifus menggunakan aplikasi dengan bahasa pemrograman python yang terlihat pada Tabel 2.

Tabel 2. Pengujian Hasil Identifikasi dengan menggunakan Aplikasi

No	Hemoglobin (g/dL)	Leukosit (μ L)	Trombosit (/cmm)	Hematokrit (%)	Sakit Kepala	Nyeri Perut	Diare	Hasil Identifikasi (Diagnosis)	Tingkat Kepercayaan
1	12.2	3809	140009	41	Tidak	Ya	Ya	Tifus	98.7%
2	13.8	17008	60009	53	Ya	Tidak	Tidak	DBD	99.3%
3	11.8	2808	155008	36	Ya	Ya	Ya	Tifus	98.9%
4	13.7	10504	78003	48	Ya	Ya	Tidak	DBD	92.3%
5	13.7	18006	55002	54	Ya	Tidak	Ya	DBD	95.1%
6	14.1	11502	83001	47	Ya	Ya	Tidak	DBD	93.4%
7	12.3	3602	120005	41	Tidak	Ya	Ya	Tifus	99.1%
...
32	11.9	3202	145009	36	Ya	Ya	Ya	Tifus	98.8%
33	11.6	2608	160010	35	Tidak	Ya	Ya	Tifus	98.9%
34	14.5	19510	66020	62	Ya	Ya	Tidak	DBD	98.9%
35	14.7	5520	88040	61	Ya	Tidak	Tidak	DBD	96.0%
36	13.8	18540	68080	58	Ya	Ya	Tidak	DBD	98.5%
37	14.6	6540	87020	57	Ya	Tidak	Tidak	DBD	96.3%
38	13.8	17580	70080	58	Ya	Ya	Tidak	DBD	98.2%

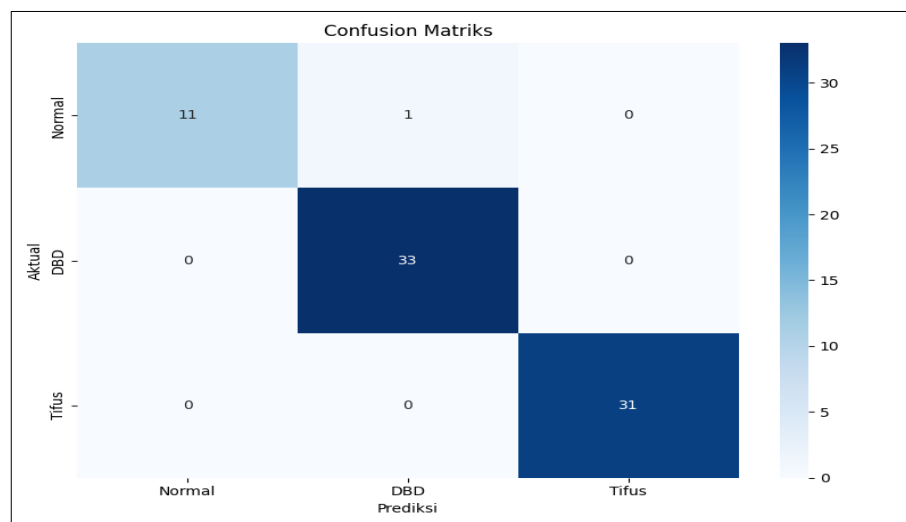
Berdasarkan Tabel 2, terlihat bahwa sistem mampu mengidentifikasi jenis penyakit dengan tingkat kepercayaan yang tinggi, sebagian besar berada di atas 90%. Parameter masukan berupa hemoglobin, leukosit, trombosit, hematokrit, serta gejala klinis seperti sakit kepala, nyeri perut, dan diare digunakan sebagai dasar dalam proses klasifikasi. Hasil identifikasi menunjukkan kesesuaian yang baik dengan diagnosis yang seharusnya, misalnya kasus dengan nilai trombosit rendah dan hematokrit tinggi cenderung terdeteksi sebagai DBD, sedangkan pola berbeda dapat mengarah pada diagnosis tifus atau kondisi normal. Tingkat akurasi yang konsisten ini membuktikan bahwa sistem yang dibangun memiliki kinerja yang andal dalam mendukung proses diagnosis. Berdasarkan hasil yang diperoleh, aplikasi menunjukkan kinerja terbaik dalam mengklasifikasikan penyakit DBD, yang ditunjukkan melalui capaian metrik evaluasi model sebagai berikut. Hasil pengujian mengindikasikan bahwa peningkatan jumlah data uji berbanding lurus dengan persentase keberhasilan klasifikasi yang dicapai sistem. Distribusi hasil prediksi model terhadap masing-masing kelas diagnosis, digunakan *Confusion Matrix* yang menampilkan jumlah prediksi benar dan salah pada setiap kategori. Matriks ini memperlihatkan gambaran detail mengenai kemampuan model dalam mengenali pola tiap kelas serta mengidentifikasi kemungkinan kesalahan klasifikasi yang terjadi. Adapun hasil *confusion matrixs* di perlihatkan pada Tabel 3.

Tabel 3. Hasil Confusion Matrix

Kelas Aktual	Prediksi Normal	Prediksi DBD	Prediksi Tifus
Normal	11	1	0
DBD	0	33	0
Tifus	0	0	31



Tabel 3 merupakan hasil Confusion Matrix menampilkan distribusi prediksi model terhadap label aktual untuk tiga kelas, yaitu Normal, DBD, dan Tifus. Nilai diagonal pada tabel menunjukkan jumlah prediksi yang tepat (True Positive), sedangkan nilai di luar diagonal menunjukkan prediksi yang salah (*False Positive* atau *False Negative*). Kelas Normal memiliki 11 prediksi benar dan 1 prediksi salah yang terklasifikasi sebagai DBD. Kelas DBD memiliki 33 prediksi benar tanpa kesalahan klasifikasi, sementara kelas Tifus juga memiliki 31 prediksi benar tanpa kesalahan. Hasil ini menunjukkan bahwa model memiliki tingkat ketepatan tinggi dalam mengidentifikasi kasus DBD dan Tifus, tersaji pada matriks hasil pengujian. Untuk mengukur performa klasifikasi secara lebih detail, digunakan confusion matrix yang menggambarkan distribusi hasil prediksi terhadap data aktual pada setiap kelas. Visualisasi hasil pengujian model tersebut ditunjukkan pada Gambar 2.



Gambar 2. Matriks Hasil Pengujian Model

Gambar 2 merupakan matriks hasil pengujian model menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama, menandakan akurasi tinggi. Model berhasil mengklasifikasikan 11 dari 12 data Normal dengan benar, seluruh 33 data DBD, dan seluruh 31 data Tifus tanpa kesalahan prediksi. Evaluasi kinerja model selanjutnya dilakukan dengan menggunakan *classification report* yang memuat metrik presisi, recall, dan *F1-Score* untuk masing-masing kelas, serta akurasi keseluruhan sistem. Metrik tersebut digunakan untuk menilai sejauh mana model mampu melakukan klasifikasi secara tepat, mendeteksi seluruh data positif secara akurat, dan menjaga keseimbangan antara presisi dan recall. Hasil *classification report* dari pengujian model ditunjukkan pada Tabel 4.

Tabel 4. Hasil *Classification Report*

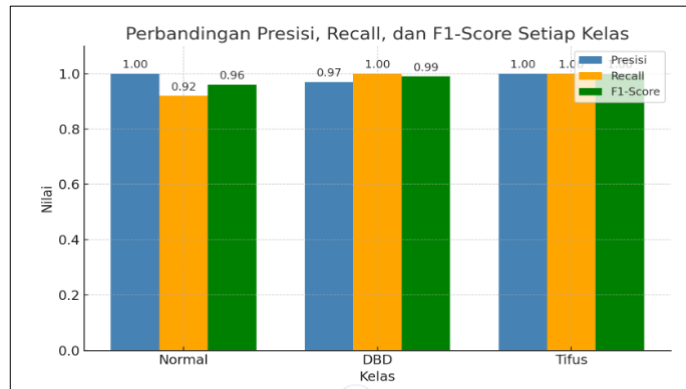
Class	Precision	Recall	F1-Score	Support
Normal	1.00	0.92	0.96	12
DBD	0.97	1.00	0.99	33
Tifus	1.00	1.00	1.00	31
Accuracy	-	-	0.99	76
Macro Avg	0.99	0.97	0.98	76
Weighted Avg	0.99	0.99	0.99	76

Berdasarkan Tabel 4 merupakan hasil *classification report*, Presisi untuk mengukur tingkat ketepatan prediksi positif yang dihasilkan oleh model, recall memperlihatkan kemampuan model dalam mengidentifikasi seluruh data positif, sedangkan *F1-Score* menggabungkan kedua metrik tersebut untuk memberikan ukuran kinerja yang seimbang. Berdasarkan hasil pengujian dengan data latih 70%, data uji sebanyak 20%, dan data validasi sebanyak 10%, sistem memperlihatkan kinerja yang optimal dengan tingkat akurasi secara keseluruhan sebesar: 98,68% (*Accuracy* = 0.9868), yang mengindikasikan tingkat keberhasilan tinggi dalam melakukan klasifikasi untuk ketiga kelas, yaitu Normal, DBD, dan Tifus.

Untuk mempermudah interpretasi hasil *classification report*, dilakukan visualisasi dalam bentuk grafik batang yang membandingkan nilai Presisi, *Recall*, dan *F1-Score* pada setiap kelas. Visualisasi ini bertujuan memberikan gambaran yang lebih jelas mengenai perbedaan kinerja model dalam mengklasifikasikan kelas Normal, DBD, dan Tifus. Adapun visualisasi hasil *classification report* tersaji pada Gambar 3.

Gambar 3 merupakan grafik hasil *classification report* menampilkan perbandingan nilai; *F1-Score*, *recall*, dan presisi pada masing - masing kelas, yaitu Normal, DBD, dan Tifus. Terlihat bahwa kelas Normal memiliki nilai presisi sempurna (1.00) dengan *recall* 0.92 dan *F1-Score* 0.96, yang menunjukkan terdapat sebagian kecil data Normal yang terklasifikasi ke kelas lain. Kelas DBD memiliki presisi 0.97, *recall* 1.00, dan *F1-Score* 0.99, yang berarti seluruh kasus DBD berhasil terdeteksi tanpa ada yang terlewat, meskipun terdapat sedikit prediksi yang tidak tepat pada kelas ini.

Sementara itu, kelas Tifus menunjukkan kinerja sempurna dengan nilai *F1-Score*, *recall*, dan presisi masing-masing sebesar 1.00, yang mengindikasikan tidak ada kesalahan klasifikasi pada kelas tersebut. Secara keseluruhan, grafik ini memperkuat hasil tabel *classification report*, di mana model memiliki performa yang sangat baik dengan akurasi keseluruhan 98,68% dan kemampuan identifikasi/diagnosis dengan konsisten untuk ketiga kelas. Evaluasi kinerja model dilakukan menggunakan metrik *classification report* yang terdiri dari presisi, *recall*, dan *F1-score* pada setiap kelas. Ketiga metrik tersebut divisualisasikan dalam bentuk grafik untuk mempermudah analisis perbandingan kinerja model pada masing-masing kategori, sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Grafik Hasil Classification Report

Berdasarkan Gambar 3, dapat dilihat bahwa model menghasilkan performa yang sangat baik pada ketiga kelas. Untuk kelas Normal, nilai presisi mencapai 1.00, *recall* 0.92, dan *F1-score* 0.96. Pada kelas DBD, diperoleh presisi 0.97, *recall* 1.00, dan *F1-score* 0.99. Sementara itu, kelas Tifus menunjukkan hasil sempurna dengan nilai presisi, *recall*, dan *F1-score* masing-masing 1.00. Hasil ini menunjukkan bahwa model memiliki tingkat akurasi yang tinggi dan mampu mengklasifikasikan data secara konsisten pada seluruh kategori yang diuji.

4. KESIMPULAN

Berdasarkan hasil penelitian dan implementasi sistem identifikasi penyakit Tifus, Demam Berdarah Dengue (DBD), dan Normal dengan menggunakan metode *deep learning Multilayer Perceptron (MLP)*, dapat disimpulkan bahwa metode ini berhasil diterapkan dengan tingkat akurasi tinggi, mencapai 98,68%. Aplikasi yang dirancang mampu memproses data parameter klinis dan menghasilkan diagnosis untuk tiga kelas, yaitu *Normal*, *DBD*, dan *Tifus*, dengan performa yang konsisten pada seluruh metrik evaluasi. Hasil *Classification Report* menunjukkan bahwa kelas *Normal* memiliki presisi 1.00, *recall* 0.92, dan *F1-score* 0.96; kelas *DBD* memiliki presisi 0.97, *recall* 1.00, dan *F1-score* 0.99; sedangkan kelas *Tifus* mencapai nilai sempurna pada seluruh metrik (1.00), menandakan tidak ada kesalahan klasifikasi. Temuan ini membuktikan bahwa model MLP yang dikembangkan memiliki kemampuan klasifikasi yang sangat baik dan berpotensi menjadi alat pendukung keputusan (*decision support system*) bagi tenaga medis dalam identifikasi dini penyakit DBD dan Tifus. Pengembangan Model selanjutnya kedepan untuk melakukan perbandingan kinerja MLP dengan metode lain, seperti; CNN atau LSTM, untuk mengidentifikasi potensi peningkatan hasil. Selain itu, hasil penelitian ini juga menunjukkan bahwa pemanfaatan metode *deep learning* dapat diintegrasikan dengan data klinis sederhana untuk menghasilkan sistem cerdas yang praktis digunakan. Dengan tampilan aplikasi interaktif dan tingkat akurasi yang tinggi, sistem ini berpotensi membantu mempercepat proses diagnosis awal, mengurangi resiko keterlambatan penanganan, serta meningkatkan efektivitas pelayanan medis.

REFERENCES

- [1] B. C. Bohm *et al.*, "Utilization of machine learning for dengue case screening," *BMC Public Health*, vol. 24, no. 1, pp. 1–9, 2024.
- [2] M. T. Phillips *et al.*, "A Bayesian approach for estimating typhoid fever incidence from large-scale facility-based passive surveillance data," *Stat. Med.*, vol. 40, no. 26, pp. 5853–5870, 2021.
- [3] S. A. alias Balamurugan, M. S. M. Mallick, and G. Chinthana, "Improved prediction of dengue outbreak using combinatorial feature selector and classifier based on entropy weighted score based optimal ranking," *Informatics Med. Unlocked*, vol. 20, no. July, p. 100400, 2020.
- [4] G. Gupta *et al.*, "DDPM: A Dengue Disease Prediction and Diagnosis Model Using Sentiment Analysis and Machine Learning Algorithms," *Diagnostics*, vol. 13, no. 6, 2023.
- [5] M. Tunay, E. Pashaei, and E. Pashaei, "Hybrid Hypercube Optimization Search Algorithm and Multilayer Perceptron Neural Network for Medical Data Classification," *Comput. Intell. Neurosci.*, vol. 2022, 2022.
- [6] L. Chen, X. Fan, K. Mao, A. Tolba, F. Alqahtani, and A. M. Ahmed, "Study of Multidimensional and High-Precision Height Model of Youth Based on Multilayer Perceptron," *Comput. Intell. Neurosci.*, vol. 2022, 2022.
- [7] J. Hwang *et al.*, "Multilayer Perceptron-Based Wearable Exercise-Related Heart Rate Variability Predicts Anxiety and Depression in College Students," *Sensors*, vol. 24, no. 13, pp. 1–13, 2024.
- [8] A. Al Bataineh and S. Manacek, "MLP-PSO Hybrid Algorithm for Heart Disease Prediction," *J. Pers. Med.*, vol. 12, no. 8, 2022.



- [9] R. Ali, J. Hussain, and S. W. Lee, "Multilayer perceptron-based self-care early prediction of children with disabilities," *Digit. Heal.*, vol. 9, 2023.
- [10] Z. Zhang *et al.*, "Multilayer perceptron-based prediction of stroke mimics in prehospital triage," *Sci. Rep.*, vol. 12, no. 1, pp. 1–8, 2022.
- [11] M. Lutz, *Learning Python*, vol. 78, no. 1. 2007.
- [12] R. Zhang, L. Wang, S. Cheng, and S. Song, "MLP-based classification of COVID-19 and skin diseases," *Expert Syst. Appl.*, vol. 228, no. March, p. 120389, 2023.
- [13] M. Wang, J. Zhang, X. Wang, B. Zhang, and Z. Yang, "Source Discrimination of Mine Water by Applying the Multilayer Perceptron Neural Network (MLP) Method—A Case Study in the Pingdingshan Coalfield," *Water (Switzerland)*, vol. 15, no. 19, 2023.
- [14] E. Joelianto *et al.*, "Convolutional neural network-based real-time mosquito genus identification using wingbeat frequency: A binary and multiclass classification approach," *Ecol. Inform.*, vol. 80, no. January, p. 102495, 2024.
- [15] M. A. R. Khan, J. Akter, I. Ahammad, S. Ejaz, and T. Jaman Khan, "Dengue outbreaks prediction in Bangladesh perspective using distinct multilayer perceptron NN and decision tree," *Heal. Inf. Sci. Syst.*, vol. 10, no. 1, pp. 1–18, 2022.
- [16] E. S. Mohamed, T. A. Naqishbandi, S. A. C. Bukhari, I. Rauf, V. Sawrikar, and A. Hussain, "A hybrid mental health prediction model using Support Vector Machine, Multilayer Perceptron, and Random Forest algorithms," *Healthc. Anal.*, vol. 3, no. March, p. 100185, 2023.
- [17] Y. Joo *et al.*, "Brain age prediction using combined deep convolutional neural network and multi-layer perceptron algorithms," *Sci. Rep.*, vol. 13, no. 1, pp. 1–15, 2023.
- [18] A. Orooji, M. Shanbehzadeh, E. Mirbagheri, and H. Kazemi-Arpanahi, "Comparing artificial neural network training algorithms to predict length of stay in hospitalized patients with COVID-19," *BMC Infect. Dis.*, vol. 22, no. 1, pp. 1–13, 2022.
- [19] X. Hu *et al.*, "Combining metabolome and clinical indicators with machine learning provides some promising diagnostic markers to precisely detect smear-positive/negative pulmonary tuberculosis," *BMC Infect. Dis.*, vol. 22, no. 1, pp. 1–16, 2022.
- [20] A. El Hadiri, L. Bahatti, A. El Magri, and R. Lajouad, "A Novel Brain-Machine Safety System Based on Drowsiness Detection using the PNN and MLP Algorithms," *IFAC-PapersOnLine*, vol. 58, no. 13, pp. 823–828, 2024.
- [21] S. Karolcik *et al.*, "Towards a machine-learning assisted non-invasive classification of dengue severity using wearable PPG data: a prospective clinical study," *eBioMedicine*, vol. 104, p. 105164, 2024.
- [22] J. K. Chaw *et al.*, "A predictive analytics model using machine learning algorithms to estimate the risk of shock development among dengue patients," *Healthc. Anal.*, vol. 5, no. November 2023, p. 100290, 2024.
- [23] Z. Mumtaz, Z. Rashid, R. Saif, and M. Z. Yousof, "Deep learning guided prediction modeling of dengue virus evolving serotype," *Heliyon*, vol. 10, no. 11, p. e32061, 2024.
- [24] T. T. Han *et al.*, "Machine learning based classification model for screening of infected patients using vital signs," *Informatics Med. Unlocked*, vol. 24, p. 100592, 2021.
- [25] A. Elhadad *et al.*, "Improved healthcare diagnosis accuracy through the application of deep learning techniques in medical transcription for disease identification," *Alexandria Eng. J.*, vol. 123, no. March, pp. 112–123, 2025.