JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.337-346

PERBANDINGAN FUNGSI OPTIMIZER PADA IDENTIFIKASI DIABETES MENGGUNAKAN METODE FEED FORWARD

Rizki Fajar Setyawan*[1)], Asrul Abdullah[2)], Barry Ceasar Octariadi[3)]
1. Universitas Muhammadiyah Pontianak, Indonesia
2. Universitas Muhammadiyah Pontianak, Indonesia

Article Info
Kata Kunci: *Adam*; *Feed Forward*; Identifikasi Diabetes; *Optimizer*; *RMSprop*

Keywords: *Adam*; *Feed Forward*; *Diabetes Identification*; *Optimizer*; *RMSprop*

Article history:
Received 2 May 2025
Revised 8 June 2025
Accepted 16 June 2025
Available online 1 March 2026

DOI :
https://doi.org/10.29100/jipi.v11i1.7757

* Corresponding author.
Corresponding Author
E-mail address:
rizkifajarsetyawan28@gmail.com

ABSTRAK
Identifikasi dini diabetes merupakan kebutuhan mendesak untuk mencegah komplikasi serius dan mengurangi beban kesehatan global. Penelitian ini bertujuan untuk membandingkan kinerja fungsi optimizer pada model Feed Forward Neural Network (FFNN) dalam mengklasifikasikan data diabetes. Optimizer yang diuji meliputi RMSprop, Adam, Adagrad, dan Stochastic Gradient Descent (SGD). Dataset diabetes dari platform Kaggle, yang terdiri dari 768 sampel dengan 9 fitur, dibagi menjadi data latih dan uji dengan rasio 80:20. Evaluasi model dilakukan menggunakan metrik Accuracy, Precision, Recall, dan F1-Score berdasarkan Confusion Matrix. Hasil penelitian menunjukkan bahwa RMSprop memberikan performa terbaik dengan akurasi sebesar 0,759740, Precision 0,660377, Recall 0,648148, dan F1-Score 0,654206, diikuti oleh Adam dengan akurasi 0,746753. RMSprop menunjukkan generalisasi yang lebih baik pada data uji berkat mekanisme pembaruan bobot adaptifnya. Penelitian ini merekomendasikan RMSprop sebagai optimizer optimal untuk model FFNN dalam identifikasi diabetes, memberikan kontribusi bagi pengembangan alat diagnosis yang lebih akurat dan efisien.

ABSTRACT
Early identification of diabetes is critical to prevent severe complications and reduce the global healthcare burden. This study aims to compare the performance of various optimizers in a Feed Forward Neural Network (FFNN) model for classifying diabetes data. The optimizers tested include RMSprop, Adam, Adagrad, and Stochastic Gradient Descent (SGD). The diabetes dataset, sourced from Kaggle, consists of 768 samples with 9 features and was split into training and testing sets with an 80:20 ratio. Model evaluation was conducted using Accuracy, Precision, Recall, and F1-Score metrics derived from the Confusion Matrix. The results demonstrate that RMSprop achieved the highest performance with an accuracy of 0.759740, Precision of 0.660377, Recall of 0.648148, and F1-Score of 0.654206, followed by Adam with an accuracy of 0.746753. RMSprop exhibited superior generalization on the test data due to its adaptive weight update mechanism. This study recommends RMSprop as the optimal optimizer for FFNN in diabetes identification, contributing to the development of more accurate and efficient diagnostic tools.

I. PENDAHULUAN

DIABETES Mellitus, yang sering disebut sebagai diabetes, merupakan salah satu penyakit kronis yang semakin memprihatinkan di seluruh dunia. Menurut International Diabetes Federation (IDF), pada tahun 2021, ada sekitar 537 juta orang yang menderita diabetes, dan angka ini diperkirakan akan meningkat menjadi 783 juta pada tahun 2045. Diabetes Mellitus ditandai oleh kadar glukosa darah yang tinggi, baik karena produksi insulin yang tidak mencukupi oleh pankreas atau karena tubuh tidak mampu menggunakan insulin secara efektif [1]. Diagnosis yang terlambat atau tidak akurat dapat memicu komplikasi serius seperti retinopati diabetik, gagal ginjal, dan penyakit kardiovaskular, yang meningkatkan angka kematian serta beban ekonomi dan sosial [2]. Oleh karena itu, pengembangan metode identifikasi dini yang akurat dan efisien menjadi prioritas untuk mendukung intervensi medis yang tepat waktu dan mengurangi dampak negatif pada kesehatan masyarakat.

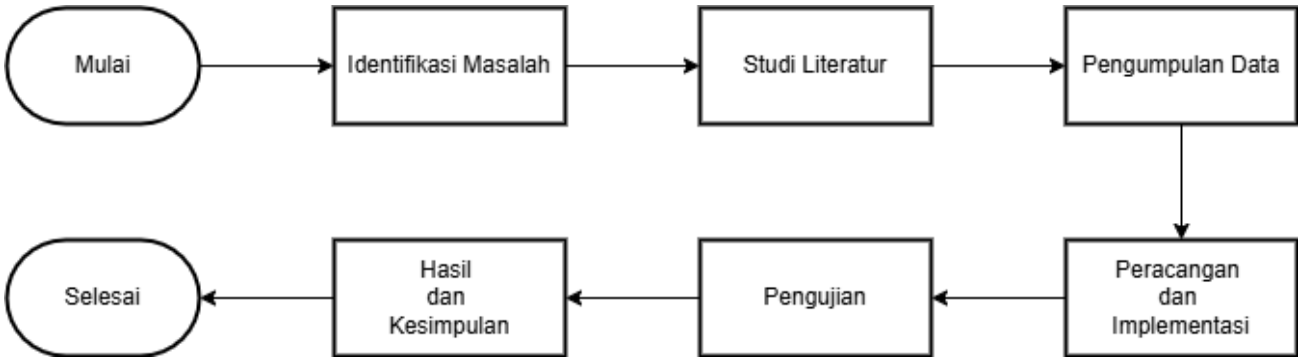
Kemajuan teknologi pembelajaran mesin (machine learning) telah merevolusi analisis data medis, memungkinkan deteksi pola kompleks yang sulit diidentifikasi dengan metode konvensional. Jaringan Syaraf Tiruan (JST), khususnya Feed Forward Neural Network (FFNN), telah menunjukkan potensi besar dalam

klasifikasi data medis untuk mendukung diagnosis penyakit seperti diabetes [2][3]. FFNN dipilih dalam penelitian ini karena kemampuannya menangani data tabular dengan hubungan non-linear, yang umum pada dataset medis seperti dataset diabetes [5]. Berbeda dengan Convolutional Neural Network (CNN), yang dioptimalkan untuk data spasial seperti gambar, atau Recurrent Neural Network (RNN), yang lebih cocok untuk data berurutan seperti time-series, FFNN menawarkan efisiensi komputasi dan akurasi tinggi untuk klasifikasi berbasis fitur numerik statis [6].

Penelitian ini bertujuan untuk membandingkan kinerja fungsi optimizer RMSprop, Adam, Adagrad, dan Stochastic Gradient Descent (SGD) pada model FFNN dalam mengidentifikasi diabetes. Meskipun studi sebelumnya telah mengeksplorasi FFNN untuk klasifikasi medis, penelitian yang secara khusus membandingkan pengaruh optimizer pada identifikasi diabetes masih terbatas. Sebagai contoh, Setiawan et al. (2024) menggunakan FFNN untuk prediksi diabetes namun tidak membahas perbandingan optimizer [7], sementara Khanam dan Foo (2021) membandingkan algoritma machine learning tanpa fokus pada optimizer spesifik [8]. Dengan mengisi celah literatur ini, penelitian ini memberikan panduan bagi klinisi dan pengembang teknologi kesehatan dalam memilih optimizer yang optimal untuk model FFNN, sehingga meningkatkan akurasi diagnosis dini diabetes. Hasil penelitian ini diharapkan dapat digunakan untuk mengembangkan alat diagnosis berbasis kecerdasan buatan yang lebih andal, mendukung pengambilan keputusan klinis yang lebih efektif, dan pada akhirnya mengurangi risiko komplikasi bagi pasien.

II. METODE PENELITIAN

Metode penelitian ini dilakukan untuk membandingkan kinerja berbagai fungsi optimizer dengan menggunakan metode Feed Forward dalam mengidentifikasi diabetes. Proses penelitian ini terdiri dari beberapa tahapan yang ditunjukkan pada Gambar 1.



Gambar 1 Metode Peneltian

Tahap pertama adalah mengidentifikasi kebutuhan metode akurat untuk deteksi dini diabetes. Feed Forward Neural Network (FFNN) dipilih karena kemampuannya dalam mengklasifikasikan data dengan akurasi tinggi. Namun, tantangan muncul pada pemilihan fungsi optimizer yang optimal. Penelitian ini membandingkan berbagai fungsi optimizer pada FFNN untuk menentukan yang paling efektif dalam identifikasi diabetes.

Tahap kedua adalah melakukan studi literatur untuk memperkuat pemahaman teori sebagai dasar dalam pengujian dan analisis penelitian. Referensi diambil dari buku, jurnal, skripsi, dan artikel yang berkaitan dengan Jaringan Syaraf Tiruan Feed Forward.

Tahap ketiga melakukan proses pengumpulan data yang menjadi komponen utama dalam penelitian. Data tersebut diambil dari platform Kaggle, yang menyediakan dataset relevan untuk mendukung analisis dan pengujian dalam penelitian ini.

Tahap keempat, dilakukan perancangan model untuk mengimplementasikan Feed Forward Neural Network (FFNN). Perancangan ini bertujuan untuk membandingkan kinerja berbagai fungsi optimizer, yaitu Adam, RMSprop, Adagrad, dan SGD, menggunakan bahasa pemrograman Python, platform Google Colaboratory, serta kerangka kerja machine learning TensorFlow dan Scikit-learn.

Tahap kelima melakukan pengujian yang bertujuan mengevaluasi kinerja model menggunakan data yang tidak terlibat dalam pelatihan. Sebanyak 20% dari total data digunakan untuk menguji kemampuan model dalam menggeneralisasi pola dari data baru. Evaluasi dilakukan menggunakan Confusion Matrix dengan metrik Accuracy, Precision, Recall, dan F1-Score. Pengujian ini juga bertujuan mengidentifikasi fungsi optimizer dengan performa terbaik dalam mendeteksi diabetes menggunakan FFNN.

Tahap keenam, setelah memperoleh hasil pengujian, kesimpulan akan diambil untuk menentukan fungsi optimizer dengan kinerja terbaik dalam identifikasi diabetes. Fungsi optimizer yang menunjukkan performa tertinggi

akan dipilih berdasarkan hasil yang diperoleh, sehingga mendukung pengambilan keputusan dalam menentukan optimizer yang paling optimal.

A. Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset diabetes yang diambil dari platform Kaggle. Dataset ini berisi 768 baris data dengan 9 atribut yang berkaitan dengan kondisi kesehatan pasien, seperti pregnacies, glucose, blood pressure, skin thickness, insulin, BMI, diabetes pedigree function, age, dan diabetes. Atribut-atribut ini akan digunakan sebagai variabel fitur dan label target dalam pengujian model pembelajaran mesin yang dirancang. Deskripsi lengkap tentang fitur dan tipe data dari dataset ini dapat dilihat pada Gambar 2.

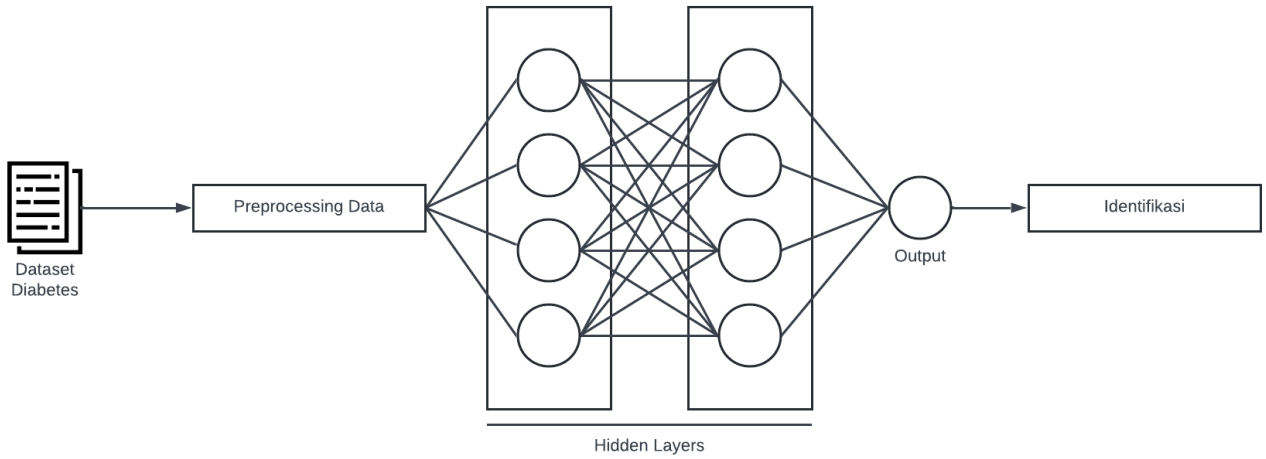
Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome
6	148	72	35	0	33.6	627	50	1
1	85	66	29	0	26.6	351	31	0
8	183	64	0	0	23.3	672	32	1
1	89	66	23	94	28.1	167	21	0
0	137	40	35	168	43.1	2.288	33	1
5	116	74	0	0	25.6	201	30	0
3	78	50	32	88	31	248	26	1
10	115	0	0	0	35.3	134	29	0
2	197	70	45	543	30.5	158	53	1
8	125	96	0	0	0	232	54	1
4	110	92	0	0	37.6	191	30	0
10	168	74	0	0	38	537	34	1
10	139	80	0	0	27.1	1.441	57	0
1	189	60	23	846	30.1	398	59	1

Gambar 2 Dataset

B. Perancangan dan Implementasi

Perancangan pada tahap ini bertujuan untuk mengimplementasikan Feed Forward Neural Network (FFNN). Pengembangan dilakukan menggunakan Python, dengan dukungan platform Google Colaboratory dan framework machine learning TensorFlow serta Scikit-learn.

Alur kerja perancangan sistem FFNN yang disajikan pada Gambar 3 bertujuan untuk mempermudah pemahaman terkait langkah-langkah yang ditempuh dalam proses perancangan model.



Gambar 3 Alur Perancangan dan Implementasi FFNN

Tahapan dalam membangun model FFNN mencakup beberapa langkah berikut:

1) Load Dataset
   Dataset diunduh dari Kaggle dan dibaca menggunakan Pamdas.
2) Preprocessing Data
   a) Pemeriksaan Tipe Data

Setiap kolom dalam dataset diperiksa untuk mengetahui tipe datanya. Hal ini dilakukan untuk memastikan bahwa setiap fitur memiliki format yang sesuai untuk digunakan dalam model. Jika terdapat kolom bertipe data kategorikal, maka perlu dilakukan konversi ke format numerik agar dapat diolah oleh model.

b) Pemeriksaan Data Duplikat
Dataset dianalisis untuk mengidentifikasi kemungkinan adanya data duplikat yang dapat mempengaruhi hasil prediksi model. Jika ditemukan duplikasi, data tersebut akan dihapus guna memastikan bahwa informasi yang diproses oleh model adalah unik dan tidak terjadi bias akibat data yang berulang.

c) Penanganan Missing Values
Dataset diperiksa untuk mengidentifikasi keberadaan nilai yang hilang atau kosong. Kehadiran nilai yang kosong dapat mempengaruhi kinerja model dalam melakukan prediksi. Oleh karena itu, data yang memiliki nilai kosong akan dihapus atau diolah lebih lanjut dengan metode imputasi yang sesuai agar dataset tetap memiliki integritas yang tinggi.

d) Memisahkan Fitur dan Target
Data dalam dataset terdiri dari beberapa variabel yang digunakan sebagai input (fitur) dan satu variabel target yang digunakan sebagai output. Variabel target adalah variabel yang merepresentasikan label atau kategori yang ingin diprediksi oleh model, dalam hal ini adalah hasil diagnosis diabetes (1 untuk positif diabetes dan 0 untuk negatif diabetes). Sementara itu, variabel lainnya berfungsi sebagai fitur yang digunakan untuk membantu model dalam melakukan prediksi.

e) Normalisasi Data
Menggunakan StandardScaler untuk menstandarkan distribusi data. Normalisasi ini membantu model lebih cepat konvergen dan menghindari masalah skala fitur yang berbeda.

f) Membagi Data Menjadi Training dan Testing
Dataset dibagi menjadi 80% data training dan 20% data testing, dengan parameter `stratify=y` untuk menjaga proporsi kelas tetap seimbang dalam kedua set data.

3) Membangun Model FFNN
   a) Menentukan jumlah lapisan dan jumlah neuron dalam setiap layer.
   b) Memilih fungsi aktivasi untuk hidden layer (ReLU) dan output layer (Sigmoid).
   c) Menggunakan berbagai jenis optimizer untuk membandingkan performa model.
4) Pelatihan Model
   a) Model dilatih selama 50 epoch dengan batch size 32, yang bertujuan untuk menemukan keseimbangan antara konvergensi dan efisiensi komputasi.
   b) Selama pelatihan, model akan terus memperbarui bobotnya berdasarkan error yang dihitung pada setiap iterasi.
5) Evaluasi Model
   a) Model diuji dengan data uji untuk menghitung metrik evaluasi seperti Accuracy, Precision, Recall, dan F1-Score.
   b) Hasil evaluasi digunakan untuk menentukan optimizer mana yang memberikan performa terbaik dalam identifikasi diabetes.

C. Activation

Fungsi aktivasi dalam jaringan syaraf tiruan adalah fungsi matematis yang digunakan oleh setiap neuron dalam model untuk mengubah input menjadi output. Fungsi aktivasi digunakan untuk menghitung nilai output berdasarkan nilai input dan bobot pada neuron [9].

Terdapat berbagai jenis fungsi aktivasi, termasuk Identity, Sign, Sigmoid, Tanh, ReLU, dan Hard Tanh. Dalam penelitian ini, fungsi aktivasi yang digunakan adalah ReLU dan Sigmoid.

1) ReLU
Rectified Linear Unit (ReLU) adalah fungsi non-linear di mana neuron diaktifkan secara selektif, hanya ketika output dari transformasi linier lebih besar dari nol [10].
ReLU dapat dituliskan pada persamaan berikut:

$$f(x) = max(0, x)$$

2) Sigmoid
Fungsi ini mengonversi nilai input menjadi nilai antara 0 dan 1, sehingga sangat cocok untuk masalah identifikasi biner di mana output-nya dapat diinterpretasikan sebagai probabilitas dari kelas positif [11].
Sigmoid dapat ditulus pada persamaan berikut:

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.337-346

$$f(x) = \frac{1}{1 + e^{-x}}$$

Tiap neuron dalam JST umumnya mempunyai fungsi aktivasi yang sendiri yang mengubah input menjadi output. Fungsi aktivasi ini bisa dipandang sebagai satu parameter model yang dapat ditingkatkan untuk memperbaiki kinerja model. Pemilihan fungsi aktivasi yang tepat juga bisa mempengaruhi tingkat kompleksitas model dan kemampuan model dalam menyelesaikan berbagai macam masalah [12].

D. Optimizer

Fungsi optimizer adalah algoritma yang digunakan untuk mengoptimalkan kinerja model pada jaringan syaraf tiruan [13]. Fungsi optimizer bertanggung jawab untuk mengubah bobot dan bias dalam jaringan syaraf tiruan agar model mampu belajar dari data dan menyesuaikan diri dengan lebih baik [14].

Dalam penelitian ini, digunakan beberapa fungsi optimizer, yaitu Adam, RMSprop, Adagrad, dan Stochastic Gradient Descent (SGD), yang masing-masing akan dibandingkan kinerjanya untuk mengetahui pengaruhnya terhadap performa model dalam mengidentifikasi diabetes.

1) Adam

Adam adalah singkatan dari Adaptive Moment Estimation, menggabungkan kedua algoritma optimisasi yaitu Adagrad dan RMSprop [15]. Optimizer Adam memperhitungkan gradien dan tingkat pembelajaran secara bersamaan [16].

Adam dapat ditulis pada rumus berikut ini:

a) Hitung rata-rata pertama (momentum):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$$

b) Hitung rata-rata kedua (RMS):

$$v_t = \beta_2 V_{t-1} + (1 - \beta_2) g_t^2$$

c) Koreksi bias:

Karena m_t dan v_t bias terhadap nol

$$\widehat{m_t} = \frac{m_t}{1 - \beta_1^t}$$

$$\widehat{v_t} = \frac{v_t}{1 - \beta_2^t}$$

d) Update parameter:

$$\theta_t = \theta_t - \alpha \frac{\widehat{m_t}}{\sqrt{\widehat{v_t} + \epsilon}}$$

2) RMSprop

RMSprop adalah singkatan dari Root Mean Squared Propagation. RMSprop merupakan algoritma optimasi yang digunakan untuk meningkatkan kecepatan konvergensi dan menemukan minimum fungsi loss dalam optimasi deep learning [17].

RMSprop dapat ditulis pada rumus berikut ini:

a) Update moving average dari kuadrat gradien:

$$v_t = \beta \times v_t + (1 - \beta) \times g_t^2$$

b) Update parameter

$$\theta_{t+1} = \theta_t - \alpha \frac{g_t}{\sqrt{v_t + \epsilon}}$$

3) Adagrad

Adagrad merupakan gabungan dari SGD dan momentum [18]. Adagrad merupakan fungsi optimizer yang dapat menyesuaikan laju pembelajaran adaptif selama proses pelatihan, sehingga setiap parameter memiliki laju pembelajaran yang berbeda yang disesuaikan berdasarkan karakteristik masing-masing bobot [19].

Adagrad dapat ditulis pada rumus berikut ini:

a) Akumulasi kuadrat gradien:

$$G_t = G_{t-1} + g_t^2$$

b) Update parameter:

$$\theta_{t+1} = \theta_t - \alpha \frac{g_t}{\sqrt{G_t + \epsilon}}$$

4) Stochastic Gradient Descent (SGD):

SGD diperkenalkan oleh Herbert Robbins dan Sutton Manro. Pada algoritma ini, istilah "stokastik" mengacu pada pemilihan data secara acak [18]. Dalam praktiknya, data dipilih secara acak untuk melatih model dan melakukan pembaruan parameter pada setiap langkah pelatihan [19].
SGD dapat ditulis pada rumus berikut:

a) Update parameter:

$$\theta_{t+1} = \theta_t - \alpha \times g_t$$

E. Confusion Matrix

Confusion Matrix (CM) adalah tabel yang menampilkan angka bulat positif untuk menunjukkan jumlah instance dari kombinasi antara label kelas yang diprediksi dan label kelas yang sebenarnya [20]. Tabel Confusion Matrix dapat dilihat pada Tabel II.

TABEL II
CONFUSION MATRIX

Predicted Class	True Class	
	Positive	Negative
Positive	True Positive	False Positive
Negative	False Negative	True Negative

- True Positive (TP): Jumlah instance yang benar-benar positif dan juga diprediksi sebagai positif oleh model. Ini berarti model berhasil mengidentifikasi positif dengan benar.
- True Negative (TN): Jumlah instance yang benar-benar negatif dan juga diprediksi sebagai negatif oleh model. Ini berarti model berhasil mengidentifikasi negatif dengan benar.
- False Positive (FP): Jumlah instance yang sebenarnya negatif tetapi diprediksi sebagai positif oleh model. Ini menunjukkan bahwa model salah mengidentifikasi negatif sebagai positif.
- False Negative (FN): Jumlah instance yang sebenarnya positif tetapi diprediksi sebagai negatif oleh model. Ini menunjukkan bahwa model gagal mendeteksi positif dan mengidentifikasikannya sebagai negatif.

Dari Confusion Matrix, didapatkan beberapa metrik evaluasi seperti:

1) Accuracy
Metrik accuracy mengukur seberapa sering model memberikan prediksi yang benar secara keseluruhan [21].
Metrik accuracy dapat ditulis dalam rumus berikut:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

2) Precision
Metrik precision mengukur seberapa banyak pola positif yang diprediksi dengan benar dibandingkan dengan total pola yang diprediksi sebagai positif [21].
Metrik precision dapat ditulis dalam rumus berikut:

$$Precision = \frac{TP}{TP + FP}$$

3) Recall
Metrik recall mengukur persentase pola positif yang teridentifikasi dengan benar dari keseluruhan pola positif [21].
Metrik recall dapat ditulis dalam rumus berikut:

$$Recall = \frac{TP}{TP + FN}$$

4) F1-Score
Menggabungkan precision dan recall ke dalam satu metrik [21].
Metrik f1-score dapat ditulis dalam rumus berikut:

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen terhadap model identifikasi diabetes yang dikembangkan menggunakan metode Feed Forward Neural Network (FFNN) dengan penerapan berbagai jenis fungsi optimizer. Evaluasi kinerja model dilakukan dengan mengukur metrik Accuracy, Precision, Recall, dan F1-Score untuk masing-masing optimizer, yakni Adam, RMSprop, Adagrad, dan SGD. Perbandingan kinerja antar optimizer disajikan secara rinci dalam Tabel III dan Gambar 4.

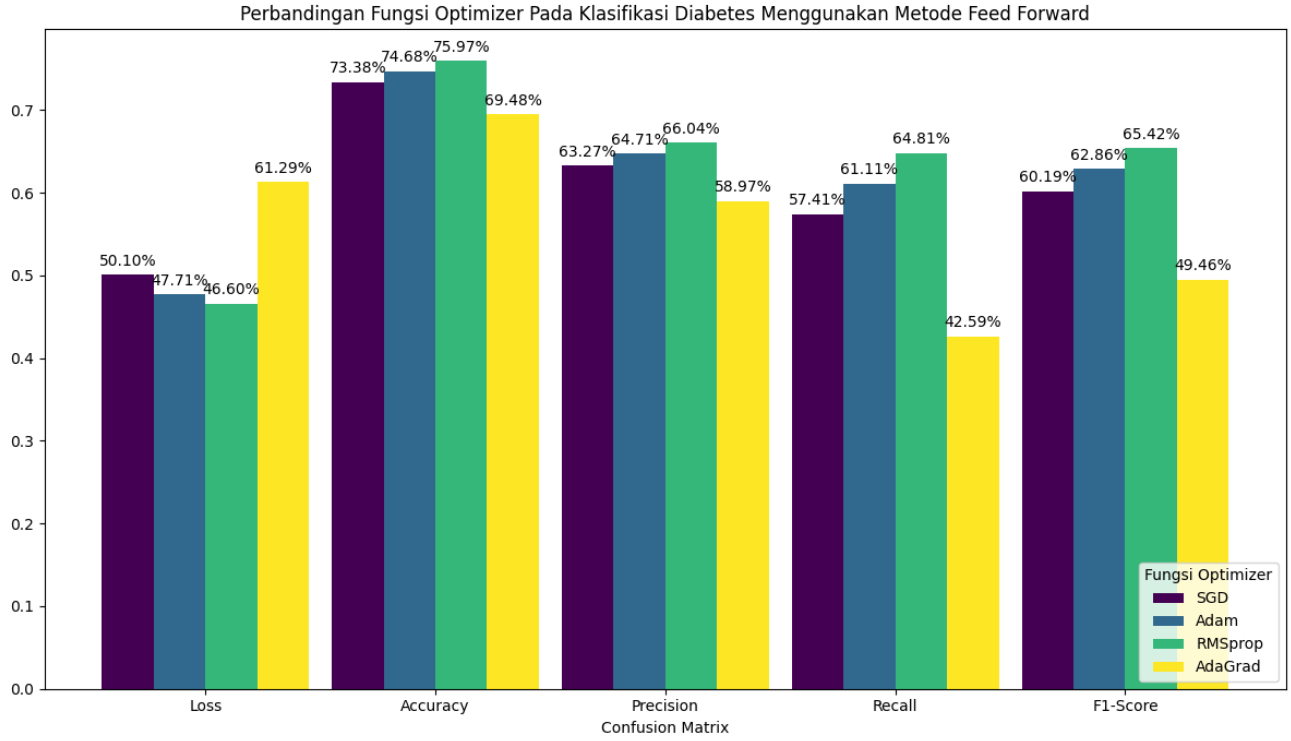
JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.337-346

TABEL IIII
HASIL PERBANDINGAN FUNGSI OPTIMIZER

Fungsi Optimizer	Confusion Matrix			
	Accuracy	Precision	Recall	F1-Score
SGD	0.733766	0.632653	0.574074	0.601942
Adam	0.746753	0.647059	0.611111	0.628571
RMSprop	**0.759740**	**0.660377**	**0.648148**	**0.654206**
Adagrad	0.694805	0.589744	0.425926	0.494624

Berdasarkan hasil evaluasi, optimizer RMSprop menunjukkan kinerja terbaik pada tiga metrik utama, yaitu Accuracy sebesar 0,759740, Precision sebesar 0,660377, Recall sebesar 0,648148, dan F1-Score sebesar 0,654206. Capaian ini mengindikasikan bahwa RMSprop mampu memberikan keseimbangan yang baik antara akurasi klasifikasi dan kemampuan deteksi terhadap kelas positif, sehingga menghasilkan performa model yang stabil dan andal.

Sebaliknya, optimizer Adagrad mencatatkan performa paling rendah dibandingkan optimizer lainnya. Nilai Accuracy yang diperoleh sebesar 0,694805, Precision sebesar 0,589744, Recall sebesar 0,425926, dan F1-Score sebesar 0,494624. Hasil ini menunjukkan bahwa Adagrad kurang efektif dalam mengidentifikasi kelas positif dan cenderung tidak optimal dalam proses pembaruan bobot model, yang berdampak pada rendahnya kinerja keseluruhan.



Gambar 4 Grafik Hasil Dari Perbandingan Fungsi Optimizer

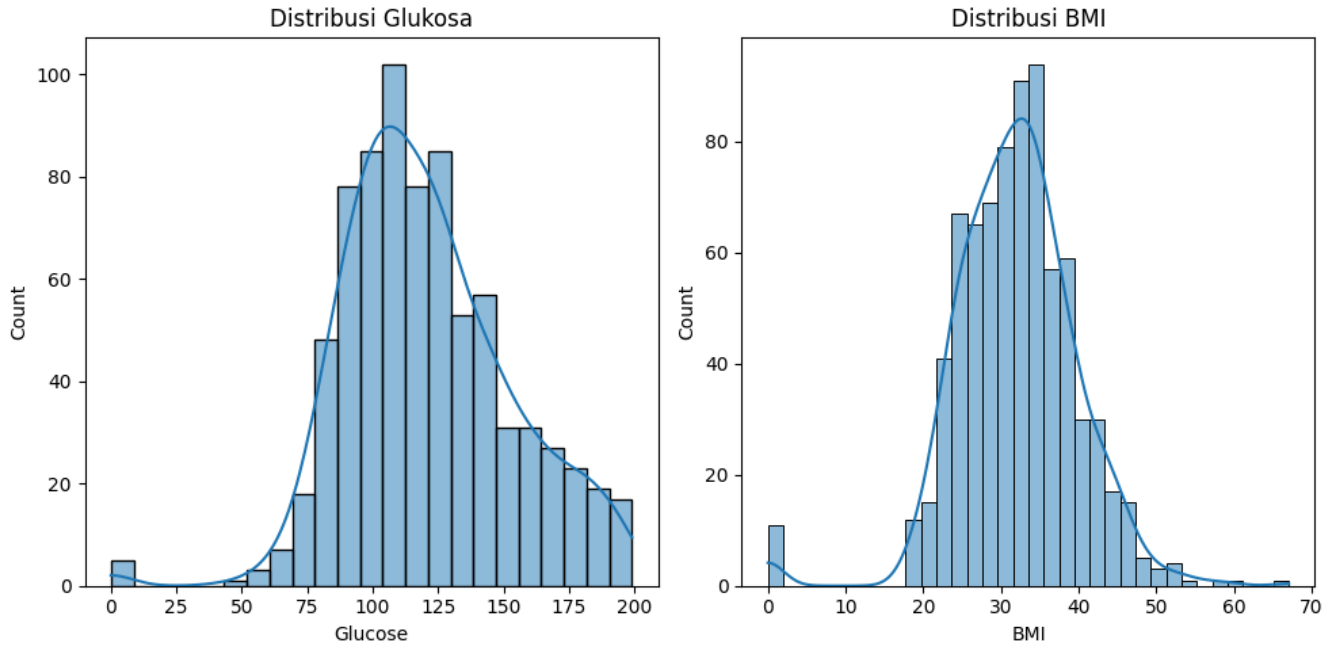
A. Perbandingan Kinerja Optimizer

Berdasarkan Tabel III, RMSprop menunjukkan kinerja terbaik dengan Accuracy 0,759740, Precision 0,660377, Recall 0,648148, dan F1-Score 0,654206, mengindikasikan keseimbangan optimal antara akurasi klasifikasi dan deteksi kelas positif (diabetes). Keunggulan RMSprop disebabkan oleh mekanisme pembaruan bobotnya yang menggunakan moving average kuadrat gradien, memungkinkan penyesuaian laju pembelajaran secara adaptif untuk fitur heterogen seperti glukosa dan BMI. Mekanisme ini meminimalkan fluktuasi gradien, meningkatkan stabilitas konvergensi dibandingkan SGD, yang rentan terhadap konvergensi lambat karena pembaruan gradien acak [8]. Adam, meskipun menggabungkan momentum dan normalisasi gradien, kurang stabil pada dataset kecil karena sensitivitas terhadap hyperparameter momentum. Adagrad, dengan laju pembelajaran yang menyusut secara monoton, kurang efektif untuk dataset dengan variabilitas tinggi, menghasilkan performa rendah (Accuracy 0,694805).

B. Pengaruh Karakteristik Dataset

Dataset Kaggle terdiri dari 768 sampel dengan 9 fitur, termasuk pregnancies, glucose, blood pressure, dan

diabetes pedigree function. Analisis distribusi fitur pada Gambar 5 menunjukkan skewness positif pada glukosa dan BMI, yang meningkatkan tantangan klasifikasi karena ketidakseimbangan kelas. RMSprop lebih efektif dalam menangani variabilitas ini melalui normalisasi gradien adaptif, sebagaimana ditemukan dalam studi dataset medis [8]. Sebaliknya, Adagrad kesulitan menyesuaikan bobot pada fitur dengan variansi tinggi, menyebabkan Recall rendah (0,425926). Jumlah sampel yang terbatas (768) juga membatasi generalisasi model, terutama untuk kelas minoritas (diabetes positif), yang dapat menyebabkan overfitting. Hal ini memengaruhi performa optimizer seperti SGD, yang kurang adaptif terhadap data kecil.



Gambar 5 Visualisasi Distribusi Fitur

C. *Perbandingan dengan Penelitian Sebelumnya*

Penelitian ini melengkapi studi-studi sebelumnya mengenai klasifikasi diabetes dengan menggunakan Feedforward Neural Networks (FNN), khususnya dengan mengeksplorasi pengaruh fungsi optimizer terhadap performa model pada dataset tabular medis. Penelitian ini juga mempertimbangkan kemampuan FNN untuk menangkap hubungan non-linear, yang sering ditemukan dalam data klinis.

Setiawan et al. (2024) melaporkan bahwa FNN yang diterapkan pada dataset tabular untuk prediksi diabetes mencapai akurasi sebesar 97% [7]. Model tersebut menggunakan arsitektur sederhana dengan fungsi aktivasi ReLU, yang memungkinkan penanganan hubungan non-linear antara fitur seperti usia, BMI, dan kadar HbA1c dengan status diabetes. Namun, penelitian mereka hanya menggunakan optimizer Adam tanpa membandingkannya dengan fungsi optimizer lain, sehingga tidak menganalisis dampak pemilihan optimizer terhadap performa model. Selain itu, recall model mereka hanya mencapai 69,1%, yang mengindikasikan perlunya peningkatan sensitivitas untuk mendeteksi kasus diabetes yang sebenarnya.

Sebaliknya, penelitian ini mencapai akurasi sebesar 75,974% dengan menggunakan optimizer RMSprop, yang menunjukkan peningkatan performa dibandingkan beberapa studi sebelumnya dengan metode lain, sekaligus menegaskan pentingnya optimasi fungsi optimizer dalam FNN. Khanam dan Foo (2021) mencatat akurasi sebesar 75% menggunakan Random Forest pada dataset serupa untuk klasifikasi diabetes [8]. Namun, penelitian mereka tidak mengeksplorasi penggunaan FNN atau perbandingan fungsi optimizer, sehingga tidak memberikan wawasan tentang potensi deep learning untuk menangani hubungan non-linear dalam data tabular medis.

Ashour et al. (2023) juga menggunakan FNN untuk klasifikasi diabetes dengan dataset tabular yang serupa, mencapai akurasi yang kompetitif [22]. Meskipun demikian, penelitian mereka tidak menganalisis penggunaan RMSprop secara spesifik dan lebih berfokus pada arsitektur FNN tanpa mengeksplorasi pengaruh optimizer terhadap performa model. Hal ini berbeda dengan pendekatan penelitian ini, yang secara eksplisit membandingkan berbagai fungsi optimizer untuk menemukan konfigurasi optimal.

Temuan penelitian ini menunjukkan bahwa fokus pada pemilihan optimizer, khususnya RMSprop, memberikan keunggulan kompetitif dalam klasifikasi diabetes menggunakan FNN pada dataset tabular medis. Penggunaan RMSprop memungkinkan konvergensi yang lebih baik dan meningkatkan akurasi dibandingkan pendekatan yang tidak mempertimbangkan optimasi fungsi optimizer, seperti yang terlihat pada penelitian Khanam dan Foo (2021).

Selain itu, kemampuan FNN untuk menangkap hubungan non-linear dalam data tabular, sebagaimana juga ditunjukkan oleh Setiawan et al. (2024) dan Ashour et al. (2023), diperkuat oleh hasil penelitian ini, yang menunjukkan bahwa optimasi yang tepat dapat memaksimalkan potensi model untuk aplikasi klinis.

D. Batasan Penelitian

Meskipun RMSprop unggul, sensitivitas terhadap hyperparameter seperti learning rate dan decay rate dapat memengaruhi stabilitas model. Ukuran dataset yang kecil (768 sampel) membatasi representasi populasi diabetes, berpotensi menyebabkan bias, terutama pada fitur seperti diabetes pedigree function yang bergantung pada riwayat keluarga. Pengujian pada satu dataset juga membatasi generalisasi hasil. Penelitian mendatang disarankan untuk menggunakan dataset yang lebih besar, menguji model pada populasi beragam, dan melakukan optimasi hyperparameter secara sistematis untuk meningkatkan robustnes model.

E. Sampel Hasil Prediksi

Tabel IV hingga VII merupakan sampel hasil prediksi yang dihasilkan oleh model untuk masing-masing jenis optimizer. Setiap sampel memuat informasi mengenai label aktual, hasil prediksi model, serta nilai probabilitas prediksi yang dihasilkan. Penyajian ini bertujuan untuk memberikan gambaran lebih rinci mengenai kemampuan masing-masing optimizer dalam mengklasifikasikan data secara individual.

TABEL IV
HASIL PREDIKSI DENGAN FUNGSI OPTIMIZER SGD

Actual	Predicted	Probability
0	1	0.6006787
0	0	0.17157282
0	0	0.29928616
1	0	0.37243617
0	0	0.0061477455

TABEL V
HASIL PREDIKSI DENGAN FUNGSI OPTIMIZER ADAM

Actual	Predicted	Probability
0	1	0.75189453
0	0	0.18845303
0	0	0.22517149
1	0	0.4276226
0	0	0.0004163153

TABEL VI
HASIL PREDIKSI DENGAN FUNGSI OPTIMIZER RMSPROP

Actual	Predicted	Probability
0	1	0.5622179
0	0	0.19762003
0	0	0.28764468
1	0	0.3878675
0	0	0.0018456307

TABEL VII
HASIL PREDIKSI DENGAN FUNGSI OPTIMIZER ADAGRAD

Actual	Predicted	Probability
0	1	0.54336953
0	0	0.4692331
0	0	0.458077
1	0	0.42179048
0	0	0.24826422

F. Analisis Hasil Prediksi

Berdasarkan analisis terhadap beberapa sampel hasil prediksi, terlihat bahwa output model berupa probabilitas dalam rentang 0 hingga 1, bukan nilai biner 0 atau 1. Proses klasifikasi dilakukan dengan menggunakan ambang batas sebesar 0,5, di mana nilai probabilitas ≥ 0,5 diklasifikasikan sebagai kelas 1, sedangkan nilai probabilitas < 0,5 diklasifikasikan sebagai kelas 0.

Dari sampel yang disajikan, dapat diamati bahwa optimizer RMSprop menghasilkan prediksi yang lebih konsisten, dengan nilai probabilitas yang cenderung lebih tinggi pada kasus-kasus yang benar-benar berlabel 1. Hal ini mendukung temuan sebelumnya pada evaluasi metrik, di mana RMSprop menunjukkan performa terbaik dalam hal Accuracy, Precision, Recall, dan F1-Score.

Sebaliknya, optimizer Adagrad memperlihatkan kecenderungan menghasilkan nilai probabilitas yang lebih rendah untuk kelas positif, yang berdampak pada meningkatnya jumlah kesalahan klasifikasi untuk kelas tersebut.

Dengan mempertimbangkan baik evaluasi metrik maupun analisis sampel prediksi, dapat disimpulkan bahwa RMSprop merupakan pilihan optimizer yang paling optimal untuk model Feed Forward Neural Network (FFNN) dalam mengidentifikasi data diabetes pada penelitian ini.

IV. KESIMPULAN

Penelitian ini membandingkan kinerja model Feed Forward Neural Network (FFNN) dengan empat optimizer: RMSprop, Adam, SGD, dan Adagrad dalam klasifikasi diabetes. Hasil menunjukkan bahwa RMSprop memberikan performa terbaik dengan Accuracy 75,97%, serta nilai Precision, Recall, dan F1-Score tertinggi. Adam menyusul dengan Accuracy 74,67% dan performa metrik yang kompetitif, sementara SGD menghasilkan Accuracy 73,38%. Adagrad menunjukkan performa terendah dengan Accuracy 69,48% dan metrik lainnya yang juga rendah. Selain evaluasi metrik, analisis prediksi menunjukkan bahwa RMSprop menghasilkan probabilitas prediksi yang lebih stabil dan akurat dalam mendeteksi kelas positif. Oleh karena itu, RMSprop direkomendasikan sebagai optimizer terbaik untuk model FFNN dalam identifikasi diabetes.

DAFTAR PUSTAKA

[1] I. Domuschiev, "Phototherapy of Diabetes Mellitus," 2024, doi: 10.13140/RG.2.2.10702.88640.
[2] M. Bergman *dkk.*, "International Diabetes Federation Position Statement on the 1-hour post-load plasma glucose for the diagnosis of intermediate hyperglycaemia and type 2 diabetes," *Diabetes Res. Clin. Pract.*, vol. 209, hlm. 111589, Mar 2024, doi: 10.1016/j.diabres.2024.111589.
[3] I. Kurniastuti, A. Andini, dan M. R. Dwisapta, "Implementation of Neural Network for Classification of Diabetes Mellitus through Finger Nail Image," *Procedia Comput. Sci.*, vol. 234, hlm. 1625–1632, 2024, doi: 10.1016/j.procs.2024.03.166.
[4] E. A. Frimpong, A. Oluwasanmi, E. Y. Baagyere, dan Q. Zhiguang, "A Feedforward Artificial Neural Network Model for Classification and Detection of Type 2 Diabetes," *J. Phys. Conf. Ser.*, vol. 1734, no. 1, hlm. 012026, Jan 2021, doi: 10.1088/1742-6596/1734/1/012026.
[5] T. Zhu, K. Li, P. Herrero, dan P. Georgiou, "Deep Learning for Diabetes: A Systematic Review," *IEEE J. Biomed. Health Inform.*, vol. 25, no. 7, hlm. 2744–2757, Jul 2021, doi: 10.1109/JBHI.2020.3040225.
[6] Y. Pan, "Different Types of Neural Networks and Applications: Evidence from Feedforward, Convolutional and Recurrent Neural Networks," *Highlights Sci. Eng. Technol.*, vol. 85, hlm. 247–255, Mar 2024, doi: 10.54097/6rn1wd81.
[7] H. Setiawan, A. Firnanda, dan U. Khair, "Enhancing the Accuracy of Diabetes Prediction Using Feedforward Neural Networks: Strategies for Improved Recall and Generalization," *Brill. Res. Artif. Intell.*, vol. 4, no. 1, hlm. 201–207, Jun 2024, doi: 10.47709/brilliance.v4i1.3888.
[8] J. J. Khanam dan S. Y. Foo, "A Comparison of Machine Learning Algorithms for Diabetes Prediction," *ICT Express*, vol. 7, no. 4, hlm. 432–439, Des 2021, doi: 10.1016/j.icte.2021.02.004.
[9] F. Damayanti, A. Rafika, dan R. Rismayanti, "Analisis Fungi Aktivasi Sigmoid Biner dan Bipolar Pada Backpropagation Dalam Mengklasifikasikan Pasien Kanker Pasca Operasi," *J. UNITEK*, vol. 16, no. 2, hlm. 237–249, Des 2023, doi: 10.52072/unitek.v16i2.687.
[10] I. Firmansyah dan B. H. Hayadi, "Komparasi Fungsi Aktivasi Relu dan Tanh Pada Multilayer Perceptron," *JIKO J. Inform. Dan Komput.*, vol. 6, no. 2, hlm. 200, Sep 2022, doi: 10.26798/jiko.v6i2.600.
[11] I. Pamungkas, S. Sumadi, dan S. Alam, "Studi Komparasi Fungsi Aktivasi Sigmoid Biner, Sigmoid Bipolar dan Linear pada Jaringan Saraf Tiruan dalam Menentukan Warna RGB Menggunakan Matlab," *J. Serambi Eng.*, vol. 7, no. 4, Okt 2022, doi: 10.32672/jse.v7i4.4776.
[12] K. Kurniawan, B. Ceasaro, dan Sucipto, "Perbandingan Fungsi Aktivasi Untuk Meningkatkan Kinerja Model LSTM Dalam Prediksi Ketinggian Air Sungai," vol. 10, no. 1, 2024, doi: 10.26418/jp.v10i1.72866.
[13] F. F. Alkhalid, "The Effect of Optimizers on Siamese Neural Network Performance," dalam *Proceedings of the International Conference on Industrial Engineering and Operations Management*, Istanbul, Turkey: IEOM Society International, Mar 2022, hlm. 5084–5089. doi: 10.46254/AN12.20221019.
[14] M. Qorich dan R. El Ouazzani, "Optimizer Algorithms and Convolutional Neural Networks for Text Classification," *IAES Int. J. Artif. Intell. IJ-AI*, vol. 13, no. 1, hlm. 451, Mar 2024, doi: 10.11591/ijai.v13.i1.pp451-458.
[15] M. Reyad, A. M. Sarhan, dan M. Arafa, "A Modified Adam Algorithm for Deep Neural Network Optimization," *Neural Comput. Appl.*, vol. 35, no. 23, hlm. 17095–17112, Agu 2023, doi: 10.1007/s00521-023-08568-z.
[16] L. Muflikhah *dkk.*, "Single Nucleotide Polymorphism Based on Hypertension Potential Risk Prediction Using LSTM With Adam Optimizer," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 33, no. 2, hlm. 1126, Feb 2024, doi: 10.11591/ijeecs.v33.i2.pp1126-1139.
[17] R. Elshamy, O. Abu-Elnasr, M. Elhoseny, dan S. Elmougy, "Improving The Efficiency of RMSprop Optimizer by Utilizing Nestrove in Deep Learning," *Sci. Rep.*, vol. 13, no. 1, hlm. 8814, Mei 2023, doi: 10.1038/s41598-023-35663-x.
[18] W. Waliidaturrahmaniah, H. Hasanuddin, dan D. Wahyuni, "Identifikasi Stroke Menggunakan Metode Transfer learning Arsitektur Convolutional Neural Network Pada Citra CT-scan Kepala," *PRISMA Fis.*, vol. 11, no. 3, hlm. 78, Okt 2023, doi: 10.26418/pf.v11i3.65242.
[19] S. Vani dan T. V. M. Rao, "An Experimental Approach Towards The Performance Assessment of Various Optimizers on Convolutional Neural Network," dalam *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, India: IEEE, Apr 2019, hlm. 331–336. doi: 10.1109/ICOEI.2019.8862686.
[20] I. Markoulidakis dan G. Markoulidakis, "Probabilistic Confusion Matrix: A Novel Method for Machine Learning Algorithm Generalized Performance Analysis," *Technologies*, vol. 12, no. 7, hlm. 113, Jul 2024, doi: 10.3390/technologies12070113.
[21] A. F. AlShammari, "Implementation of Model Evaluation Using Confusion Matrix in Python," *Int. J. Comput. Appl.*, vol. 186, no. 50, hlm. 42–48, Nov 2024, doi: 10.5120/ijca2024924236.
[22] A. F. Ashour, M. M. Fouda, Z. M. Fadlullah, dan M. I. Ibrahem, "Optimized Neural Networks for Diabetes Classification Using Pima Indians Diabetes Database," dalam *2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI)*, Mt Pleasant, MI, USA: IEEE, Apr 2024, hlm. 1–7. doi: 10.1109/ICMI60790.2024.10585703.