



Pemodelan Prediktif *Diabetes* Menggunakan Pendekatan *Multimodel Machine Learning* dan *Deep Learning*

Afandi Alsyar¹, Riski Amin Putra², Winson Ardhika Ramadhani³, Fadli Rahmad Hidayatullah⁴, Edi Ismanto⁵

Email: ¹230401012@student.umri.ac.id, ²230401016@student.umri.ac.id ³230401014@student.umri.ac.id, ^{230401033@student.umri.ac.id}, ⁵edi.ismanto@umri.ac.id

^{1,2,3,4,5}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

Diterima: 25 Juli 2025 | Direvisi: 06 Agustus 2025 | Disetujui: 10 Agustus 2025

©2025 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Penelitian ini membahas implementasi dan evaluasi berbagai algoritma *machine learning* serta satu model *deep learning* untuk prediksi penyakit *diabetes* berdasarkan data medis pasien. *Dataset* yang digunakan telah melalui proses *Preprocessing* meliputi *Encoding* fitur kategorikal, *feature scaling*, dan *train-test split*. Algoritma yang dibandingkan dalam studi ini meliputi *Logistic regression*, *Decision Tree*, *Random Forest*, dan *K-Nearest Neighbors (KNN)*. Selain itu, model *Multilayer Perceptron (MLP)* dibangun menggunakan *Keras* untuk mengeksplorasi pendekatan *deep learning* dengan pemanfaatan *epoch* dan *batch size*. Evaluasi performa dilakukan menggunakan metrik *accuracy*, *precision*, dan *recall*, serta *visualisasi learning curve* untuk menganalisis konvergensi model selama pelatihan. Hasil evaluasi menunjukkan bahwa model *Random Forest* menghasilkan akurasi terbaik di antara algoritma tradisional, sementara *MLP* memberikan hasil kompetitif dengan keunggulan pada aspek *generalisasi*. Penggunaan *visualisasi loss* dan akurasi per *epoch* memberikan pemahaman lebih mendalam tentang perilaku model selama proses pelatihan. Studi ini menunjukkan bahwa kombinasi antara teknik praproses data yang tepat dan pemilihan model yang sesuai sangat berpengaruh terhadap akurasi prediksi penyakit. Penelitian ini dapat menjadi acuan awal dalam pengembangan sistem prediksi medis berbasis data dan mendukung pengambilan keputusan klinis berbantuan komputer (*clinical decision support systems*).

Kata kunci: *Diabetes*, Klasifikasi, *Machine Learning*, *Deep Learning*, *MLP*

Predictive Modeling of Diabetes Using Multimodel Machine learning and Deep learning Approaches

Abstract

This study discusses the implementation and evaluation of various machine learning algorithms along with one deep learning model for predicting diabetes based on patient medical data. The dataset underwent Preprocessing steps including categorical feature Encoding, feature scaling, and train-test split. The algorithms compared in this study include Logistic regression, Decision Tree, Random Forest, and K-Nearest Neighbors (KNN). Additionally, a Multilayer Perceptron (MLP) model was developed using Keras to explore a deep learning approach with the use of epochs and batch size. The model performance was evaluated using accuracy, precision, and recall metrics, along with learning curve visualizations to analyze model convergence during training. The evaluation results showed that the Random Forest model achieved the highest accuracy among traditional algorithms, while the MLP provided competitive results with strengths in generalization. Visualization of loss and accuracy per epoch offered deeper insight into model behavior throughout the training process. This study demonstrates that a combination of proper data Preprocessing techniques and appropriate model selection significantly influences prediction accuracy. The findings may serve as an early reference for the development of data-driven medical prediction systems and support computer-assisted clinical decision-making (clinical decision support systems).

Keywords: *Diabetes*, Classification, *Machine Learning*, *Deep Learning*, *MLP*

1. PENDAHULUAN

Kesehatan merupakan peranan yang sangat penting untuk mempertahankan kehidupan manusia. Dengan kesehatan yang baik, manusia dapat melakukan kegiatan produktif dalam sosialisasi atau ekonomi untuk mencapai tujuan hidup mereka. Salah satu penyakit yang dapat menyebabkan komplikasi dan kematian adalah *diabetes*. *Diabetes* bukan hanya penyebab utama kematian dini di dunia, penyakit ini dapat menyebabkan kebutaan, gagal ginjal, dan bahkan penyakit jantung [1]. Penyakit ini ditandai oleh tingginya kadar glukosa dalam darah yang disebabkan oleh ketidakmampuan tubuh untuk memproduksi atau menggunakan *insulin* secara efektif [2]. Dalam tes kesehatan tersebut, dihasilkan data terkait gejala-gejala yang muncul, seperti: mudah haus, riwayat keluarga dengan penyakit *diabetes mellitus*, turunnya berat badan tanpa sebab yang jelas, sering buang air kecil di malam hari, luka yang sulit untuk sembuh, tekanan darah tinggi, dan gula darah tinggi [3]. *Diabetes* diklasifikasikan menjadi empat kategori klinis, yaitu *T1DM*, *T2DM*, *diabetes gestasional (GDM)*, dan jenis *diabetes* spesifik lainnya yang disebabkan oleh penyebab lain, seperti cacat genetik dalam fungsi sel β , cacat genetik dalam aksi *insulin*, atau penyakit pankreas eksokrin [4]. Perilaku hidup masyarakat saat ini telah mengalami banyak metamorfosis, berlaku bagi remaja maupun dewasa [5]. *Diabetes* dapat menyerang semua kalangan dan semua umur. Seseorang yang memiliki riwayat keturunan *diabetes* dalam keluarga memiliki risiko terkena *diabetes* lebih tinggi. Hal ini diperparah jika didukung dengan kebiasaan pola makan yang tidak baik [6].

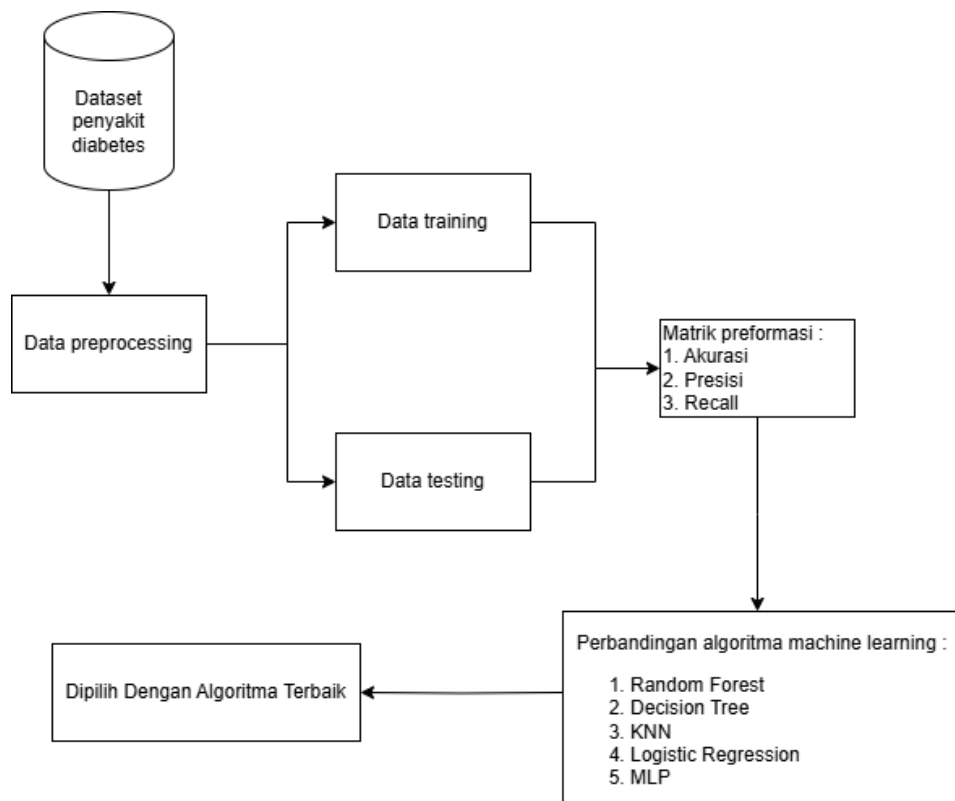
Diabetes yaitu gangguan metabolisme yang diidentifikasi melalui *hiperglikemia* yang diakibatkan oleh ketidak mampuan pankreas untuk mensekresi *insulin*, gangguan kerja *insulin*. Kondisi *hiperglikemik* kronis dapat menimbulkan kerusakan berkepanjangan dan tidak berfungsinya beberapa organ seperti mata, ginjal, jantung, dan pembuluh darah. Menurut *International Diabetes Federation (IDF)*, 433 juta manusia di seluruh dunia menderita *diabetes* pada tahun 2019. Total itu diproyeksikan meningkat 578 juta pada 2030 dan 700 juta lagi pada 2045. Indonesia sendiri termasuk kedalam salah satu dari 10 negara dengan total penderita *diabetes* terbesar di dunia di tahun 2019. Dengan melihat banyaknya total kasus *diabetes*, maka memerlukan tindakan awal untuk tindakan dini penyakit *diabetes* dengan melakukan *prediksi* [7].

Diabetes adalah penyakit kronis yang paling umum di dunia, dan kejadiannya meningkat dengan cepat. Menurut laporan 2021 oleh *International Diabetes Union*, sekitar 537 juta orang telah didiagnosis di seluruh dunia. Sekitar 783 juta pasien diperkirakan akan didiagnosis pada tahun 2045. Sangat penting untuk memeriksa prediktor risiko *diabetes* dan penyebab utama penyakit [8]. Dari uraian diatas maka perlu sekali melakukan deteksi dini penyakit *diabetes* mengingat *diabetes* merupakan salah satu penyakit kronis yang mematikan, serta Penyakit *Diabetes* di Indonesia semakin meningkat, salah satu cara untuk menghentikan peningkatan pasien *diabetes* maka dengan melakukan deteksi dini dengan melihat faktor-faktor yang menyebabkan penyakit *diabetes* [9].

Fenomena ini menunjukkan bahwa diabetes bukan lagi sekadar masalah kesehatan individu, melainkan isu global yang memerlukan solusi inovatif dan efisien dalam deteksi serta penanganannya. Peningkatan prevalensi ini juga menyoroti urgensi untuk mengembangkan alat bantu diagnosis yang dapat diakses secara luas. Fenomena saat ini menunjukkan bahwa proses diagnosis masih banyak dilakukan secara manual oleh tenaga medis, sehingga rentan terhadap keterlambatan atau kesalahan diagnosa karena keterbatasan waktu dan sumber daya manusia. *Machine learning* merupakan cabang dari ilmu kecerdasan buatan (*artificial intelligence*) yang berfokus pada pengembangan model atau algoritma yang mampu belajar dari data dan membuat prediksi atau keputusan tanpa diprogram secara eksplisit [10]. Penelitian ini bertujuan untuk menganalisis dan membandingkan performa empat algoritma *machine learning* *Logistic regression* [11], *Decision Tree*, *Random Forest*, *K-Nearest Neighbor (KNN)*. *Machine learning* dalam hal ini dapat digunakan untuk membantu seseorang mengenali lebih dini mengenai risiko penyakit *diabetes*. Setiap algoritma memiliki pendekatan yang berbeda dalam memproses data, dengan kelebihan dan kekurangannya masing-masing [12]. *Deep learning* menggunakan sejumlah besar data untuk mendekati atau memodelkan fungsi-fungsi kompleks yang memiliki jarak yang jauh antara *input* dan *output*. Contohnya, sebuah Gambar dapat digunakan sebagai *input*, lalu dihasilkan *output* berupa teks yang mendeskripsikan Gambar tersebut. Contoh lainnya adalah naskah tertulis yang dijadikan *input*, kemudian diubah menjadi suara yang terdengar alami saat membacakan naskah tersebut. Bahkan dalam bentuk yang lebih sederhana, *deep learning* dapat menghubungkan Gambar seekor anjing *golden retriever* dengan sebuah penanda yang menyatakan, “Ya, seekor *golden retriever* ada dalam Gambar ini” [13]. Klasifikasi merupakan salah satu jenis *subset* dalam *machine learning* yang dapat digunakan untuk mengklasifikasikan suatu hal kedalam salah satu jenis kategori. Dalam hal ini, *machine learning* dapat digunakan untuk melakukan klasifikasi terhadap gejala yang diberikan apakah gejalagejala tersebut masuk kedalam penyakit *diabetes* atau tidak. Dengan demikian, penelitian ini memiliki potensi untuk memberikan kontribusi yang signifikan dalam meningkatkan kualitas hidup penderita *diabetes* dan mencegah komplikasi yang berpotensi mengancam kesehatan mereka [14].

2. METODE PENELITIAN

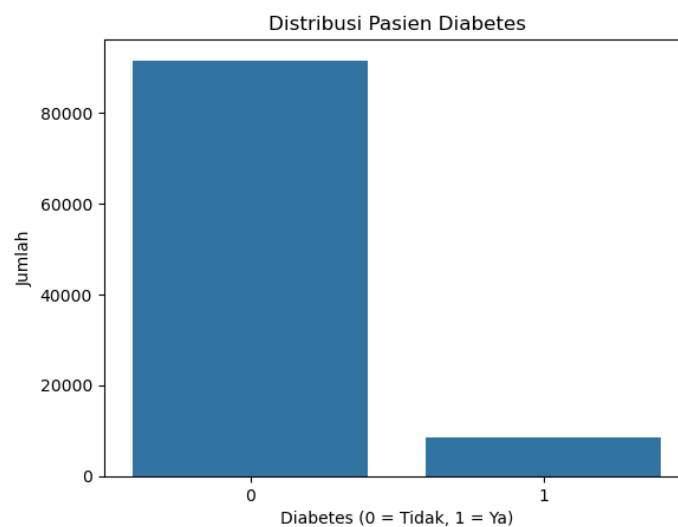
Berikut adalah alur metode penelitian yang dilakukan yang terGambar pada Gambar1.



Gambar 1. Metode Penelitian

2.1 Dataset

Permasalahan yang diangkat dalam penelitian ini adalah bagaimana memanfaatkan data medis pasien secara optimal untuk memprediksi risiko *diabetes* dengan akurasi tinggi. Metode diagnosis konvensional seperti pemeriksaan laboratorium memerlukan waktu, biaya, dan tidak selalu tersedia di seluruh fasilitas kesehatan. Hal ini menjadi tantangan dalam upaya deteksi dini *diabetes*, terutama di wilayah dengan keterbatasan tenaga medis dan infrastruktur. Oleh karena itu, diperlukan pendekatan prediktif berbasis data untuk mengidentifikasi individu berisiko *diabetes* secara cepat dan akurat. *Dataset* yang digunakan dalam penelitian ini terdiri dari 100.000 data pasien yang mencakup fitur-fitur medis seperti usia, jenis kelamin, riwayat merokok, hipertensi, penyakit jantung, *BMI*, *HbA1c*, dan kadar glukosa darah. Masalah utama yang dianalisis adalah bagaimana mengolah data ini dan memilih algoritma prediksi yang mampu menghasilkan performa terbaik dalam klasifikasi kondisi *diabetes*.



Gambar 2. Distribusi pasien *diabetes*

Pada Gambar 2. menunjukkan distribusi pasien berdasarkan status *diabetes* yang dibedakan dalam dua kategori, yaitu pasien yang tidak menderita *diabetes* (label 0) dan pasien yang menderita *diabetes*. Dari *visualisasi* terlihat bahwa jumlah pasien tanpa *diabetes* jauh lebih banyak dibandingkan pasien yang terdiagnosis *diabetes*. Tercatat sekitar 90.000 pasien termasuk dalam kategori *non-diabetes*, sedangkan hanya sekitar 10.000 pasien yang termasuk kategori *diabetes*. Ketimpangan ini menunjukkan bahwa data yang digunakan bersifat tidak seimbang (*imbalanced*), di mana jumlah kelas mayoritas (*non-diabetes*) mendominasi secara signifikan. Ketidakseimbangan ini dapat berdampak pada performa model klasifikasi, karena model cenderung lebih akurat dalam mengenali kelas mayoritas, namun lemah dalam mendeteksi kelas minoritas yang sebenarnya lebih penting secara klinis. Oleh karena itu, perlu dilakukan penyesuaian seperti pemberian bobot kelas atau teknik *resampling* agar model dapat mengklasifikasikan kedua kelas dengan lebih seimbang dan adil.

2.2 Data Preprocessing

Preprocessing data merupakan tahap penting dalam proses analisis prediktif yang bertujuan untuk meningkatkan kualitas dan kesiapan data sebelum digunakan dalam pelatihan model. Langkah pertama yang dilakukan adalah pemeriksaan terhadap nilai-nilai yang hilang atau tidak valid, khususnya pada fitur *smoking_history*. Ditemukan sejumlah data dengan nilai *No Info* yang tidak dihapus, melainkan di-*imputasi* menggunakan algoritma *K-Nearest Neighbors (KNN)*. Proses ini mempertimbangkan kemiripan atribut numerik lain seperti *age*, *hypertension*, *heart_disease*, *BMI*, *HbA1c_level*, dan *blood_glucose_level*, dengan tujuan mempertahankan sebanyak mungkin informasi dalam *dataset*. Setelah *imputasi* selesai, fitur *smoking_history* dikonversi ke dalam bentuk numerik menggunakan metode *Label encoding* agar dapat diproses oleh algoritma *machine learning*. Fitur *gender* tidak mengalami *encoding* dan tetap disimpan dalam format *string* karena tidak mengganggu proses pelatihan model yang digunakan.

2.3 Pembagian Data

Setelah melalui proses *Preprocessing*, *dataset* dibagi menjadi dua *subset* utama: data latih (*training data*) dan data uji (*testing data*). Pembagian ini bertujuan untuk memastikan model yang dibangun dapat dievaluasi secara objektif pada data yang belum pernah dilihat sebelumnya. Dengan demikian, kinerja model tidak hanya diukur dari kemampuannya mengenali pola dalam data latih, tetapi juga dari kemampuannya melakukan *generalisasi* terhadap data baru. Dalam penelitian ini, data dibagi dengan rasio 80:20, di mana 80% data digunakan untuk melatih model dan 20% sisanya digunakan untuk menguji performa model. Proses pembagian dilakukan secara acak namun terkontrol menggunakan parameter *random_state* pada fungsi *train_test_split* dari pustaka *Scikit-Learn*. Hal ini dilakukan agar hasil eksperimen dapat direproduksi secara konsisten oleh peneliti lain. Semua fitur dalam kedua subset tersebut telah melalui tahap *Encoding* dan *normalisasi* agar data memiliki format dan skala yang seragam.

2.4 Develop Model

Model dikembangkan dengan lima algoritma klasifikasi: *Logistic Regression*, *Decision Tree*, *Random Forest*, *K-Nearest Neighbor (KNN)*, dan *Multilayer Perceptron (MLP)*.

1. *Logistic regression* digunakan sebagai *baseline* model.
2. *Decision Tree* dan *Random Forest* digunakan karena kemampuannya menangani data numerik dan kategorikal sekaligus.
3. *KNN* digunakan untuk klasifikasi berdasarkan kedekatan fitur.
4. *MLP* (*Multilayer Perceptron*) dibangun menggunakan arsitektur dua *hidden layer* dan satu *output layer* menggunakan pustaka *Keras*, dengan aktivasi *ReLU* dan *sigmoid*, serta optimizer *Adam* dan fungsi *loss binary_crossentropy*.

2.5 Evaluasi Model

Evaluasi model dilakukan dengan mengukur metrik *accuracy*, *precision*, dan *recall*. Evaluasi dilakukan terhadap data uji untuk menilai kemampuan *generalisasi* model. Selain itu, untuk analisis visual dilakukan *plotting confusion matrix* dan *bar chart* evaluasi. Model dievaluasi menggunakan pendekatan *macro average* agar semua kelas memiliki kontribusi yang seimbang terhadap nilai metrik. Dalam *confusion matrix* terdapat *False Negative (FN)*, *False Positive (FP)*, *True Negative (TN)*, dan *True Positive (TP)*. Berikut merupakan tabel dari *confusion matrix*.

Tabel 1. Asumsi *Confusion Matrix*

Kelas Prediksi	Kelas Aktual	
	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	TP	FP
<i>Negative</i>	FN	TN

TP adalah kondisi dimana baik prediksi maupun nilai aktualnya benar; FN adalah kasus dimana nilai prediksi tidak benar tetapi nilai aktualnya benar; FP adalah kasus dimana nilai prediksi benar tapi nilai aktualnya tidak benar. Dalam mengevaluasi kinerja model, ada berbagai macam performa diantaranya akurasi, *recall*, dan presisi. Nilai akurasi, *recall*, dan presisi dapat diperoleh dengan menggunakan persamaan pada Tabel 2.

Tabel 2. Rumus Evaluasi Performa Metode

Performance Metrics	Rumus
Akurasi	$\frac{TP + TN}{TP + TN + FP + FN} \times 100\%$
Recall	$\frac{TP}{TP + FN} \times 100\%$
Presisi	$\frac{TP}{TP + FP} \times 100\%$

Akurasi merupakan rasio prediksi benar dengan keseluruhan data. *Recall* adalah rasio prediksi benar positif dibandingkan dengan keseluruhan data aktual positif. Presisi merupakan rasio prediksi benar positif dibandingkan dengan seluruh data yang diprediksi positif [15].

3. HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan lima model klasifikasi untuk memprediksi risiko *diabetes* berdasarkan data medis pasien. Model yang digunakan terdiri dari empat algoritma *machine learning* tradisional, yaitu *Logistic Regression*, *Decision Tree*, *Random Forest*, dan *K-Nearest Neighbor (KNN)*, serta satu algoritma *deep learning* yaitu *multilayer perceptron (MLP)*. Evaluasi performa model dilakukan dengan menggunakan metrik *accuracy*, *precision*, dan *recall* untuk mengukur seberapa baik masing-masing model dalam mengenali kasus *diabetes*.

Setelah data diproses dan dibagi menjadi data latih dan data uji, seluruh model dilatih menggunakan data latih dan kemudian diuji pada data uji sebanyak 20.000 data (20% dari total *dataset*). Hasil evaluasi ditunjukkan pada Tabel 1 berikut:

Tabel 3. Hasil Evaluasi Model Prediksi *Diabetes*

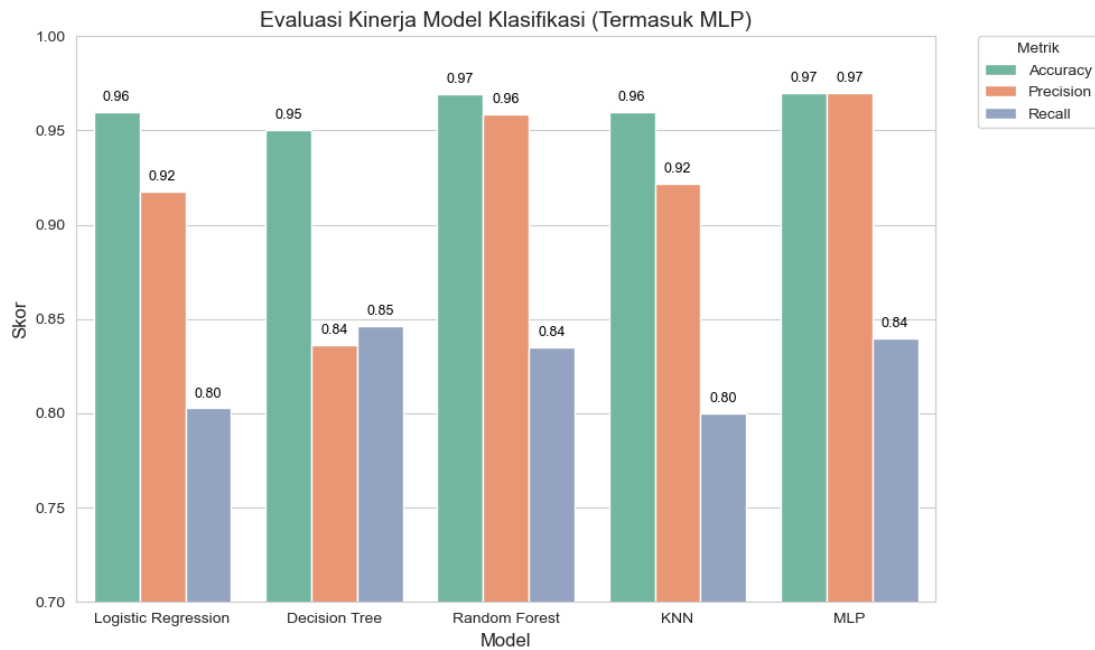
No	Model	Accuracy	Precision	Recall
1	<i>Logistic regression</i>	0.95960	0.91768	0.80269
2	<i>Decision Tree</i>	0.95010	0.83636	0.84607
3	<i>Random Forest</i>	0.96920	0.95872	0.83504
4	<i>K-Nearest Neighbor (KNN)</i>	0.95975	0.92201	0.79982
5	<i>Multilayer Perceptron (MLP)</i>	0.97000	0.97000	0.84000

Berdasarkan hasil pada Tabel 3, model *Multilayer Perceptron (MLP)* memberikan hasil terbaik di antara seluruh model, dengan nilai akurasi dan presisi tertinggi (0.970 dan 0.970), serta *recall* yang cukup tinggi (0.840). Hal ini menunjukkan bahwa model *deep learning* mampu menangkap pola kompleks dalam data dan melakukan *generalisasi* yang baik terhadap data uji.

Model *Random Forest* menempati posisi kedua dengan akurasi 0.96920 dan presisi 0.95872. Meskipun *recall*-nya sedikit lebih rendah dibandingkan *Decision Tree* (0.83504), model ini menunjukkan kinerja yang stabil dan sangat akurat. *Logistic regression* dan *KNN* menampilkan performa yang hampir seimbang dengan akurasi masing-masing sebesar 0.95960 dan 0.95975, namun dengan *recall* yang lebih rendah dari *Random Forest* dan *MLP*. Ini menunjukkan bahwa kedua model tersebut cenderung lebih konservatif dalam mengidentifikasi kasus positif (*diabetes*), sehingga dapat menghasilkan lebih banyak false negative.

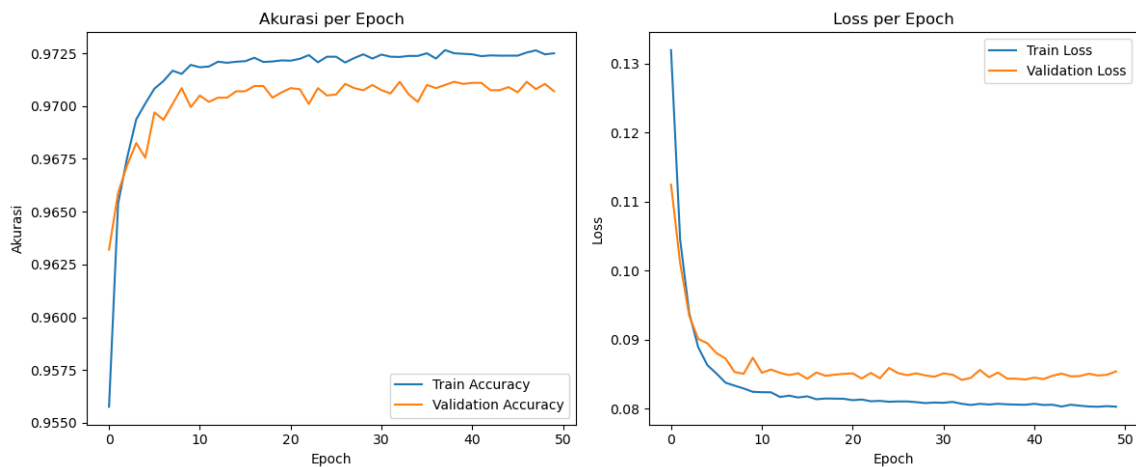
Sementara itu, model *Decision Tree* memiliki keunggulan pada metrik *recall* yaitu sebesar 0.84607, yang merupakan tertinggi di antara seluruh model. Hal ini menunjukkan bahwa *Decision Tree* lebih sensitif dalam menangkap kasus *diabetes*, meskipun presisinya sedikit lebih rendah. Model ini mungkin lebih sesuai digunakan dalam kondisi di mana deteksi dini kasus positif lebih diutamakan dibanding risiko prediksi palsu.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model dengan pendekatan *ensemble* seperti *Random Forest* dan pendekatan *deep learning* seperti *MLP* memiliki keunggulan dalam hal akurasi dan kestabilan hasil prediksi. *Visualisasi* hasil evaluasi yang disajikan dalam bentuk grafik batang memperlihatkan bahwa *MLP* unggul dalam hampir seluruh metrik, sementara *Random Forest* tetap menjadi pilihan terbaik dalam kategori *machine learning* tradisional.



Gambar 3. Evaluasi Kinerja Model

Temuan ini menegaskan bahwa pemilihan algoritma yang tepat dan proses *Preprocessing* data yang optimal dapat memberikan kontribusi besar terhadap keberhasilan sistem prediksi medis. *MLP*, meskipun secara komputasi lebih berat, terbukti menghasilkan prediksi yang unggul dan dapat diandalkan dalam kasus klasifikasi penyakit seperti *diabetes*.



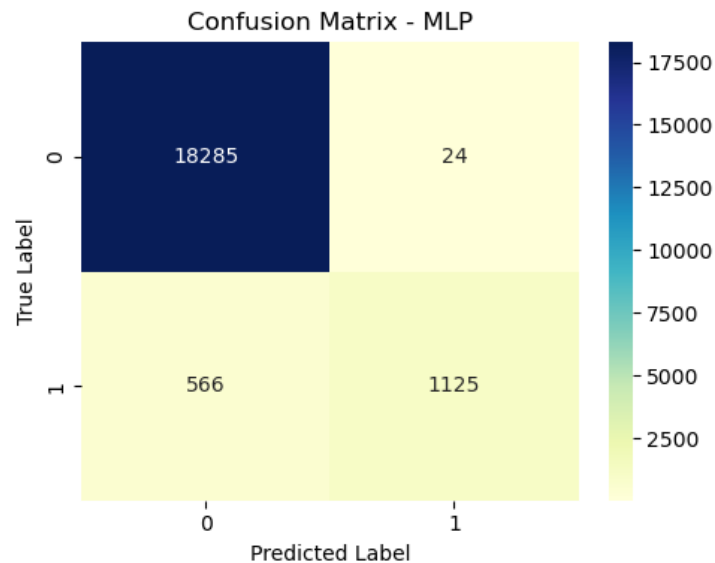
Gambar 4. Perbandingan Akurasi dan Loss Model MLP

Gambar di atas menampilkan dua grafik yang menggambarkan kinerja model *Multilayer Perceptron (MLP)* selama proses pelatihan selama 50 *epoch*, yaitu akurasi per *epoch* (grafik kiri) dan *loss per epoch* (grafik kanan). Grafik ini berfungsi untuk mengevaluasi kemampuan model dalam belajar dari data serta kecenderungan *overfitting* atau *underfitting*.

Pada grafik sebelah kiri, terlihat bahwa akurasi model pada data latih (*Train Accuracy*) meningkat tajam di awal pelatihan dan mencapai nilai yang cukup stabil mendekati 0.973 setelah sekitar 10 *epoch*. Akurasi validasi (*Validation Accuracy*) juga mengikuti tren yang mirip, meskipun sedikit lebih rendah dibandingkan data latih, dan cenderung stabil di angka sekitar 0.970. Hal ini menunjukkan bahwa model mampu belajar dengan baik tanpa mengalami penurunan performa yang signifikan pada data validasi.

Sementara itu, grafik sebelah kanan menunjukkan nilai *loss* pada data latih dan validasi. Baik *Train Loss* maupun *Validation Loss* mengalami penurunan tajam di awal *epoch*, yang menandakan proses pembelajaran berjalan efektif. Setelah sekitar *epoch* ke-10, nilai *loss* mulai stabil. Nilai *loss* pada data validasi sedikit lebih tinggi dibandingkan data latih, tetapi perbedaannya tidak terlalu besar, yang menunjukkan bahwa model tidak mengalami *overfitting* secara signifikan.

Secara keseluruhan, grafik ini memperlihatkan bahwa model *MLP* yang dibangun memiliki kinerja yang baik dan stabil, dengan akurasi tinggi serta *loss* rendah pada kedua jenis data. Ini mengindikasikan bahwa arsitektur dan parameter yang digunakan sudah cukup optimal untuk menyelesaikan tugas klasifikasi *diabetes* pada *dataset* yang diberikan.



Gambar 5. Confusion Matrix – MLP

Gambar di atas merupakan *confusion matrix* dari model *Multilayer Perceptron (MLP)* yang digunakan untuk klasifikasi status *diabetes*. Matriks ini menunjukkan jumlah prediksi yang benar dan salah dari model terhadap data uji. Dari hasil yang ditampilkan, sebanyak 18.285 pasien yang tidak menderita *diabetes* (kelas 0) berhasil diklasifikasikan dengan benar (*true negative*), sementara hanya 24 pasien *non-diabetes* yang salah diklasifikasikan sebagai *diabetes* (*false positive*). Untuk pasien yang benar-benar menderita *diabetes* (kelas 1), model berhasil memprediksi secara tepat sebanyak 1.125 kasus (*true positive*), namun masih terdapat 566 kasus *diabetes* yang tidak terdeteksi oleh model atau salah diklasifikasikan sebagai *non-diabetes* (*False Negative*).

Secara umum, hasil ini menunjukkan bahwa model *MLP* memiliki akurasi yang sangat tinggi dalam mengenali pasien tanpa *diabetes* dan cukup baik dalam mendeteksi pasien dengan *diabetes*. Nilai *false positive* yang sangat kecil menandakan bahwa model jarang memberikan prediksi positif palsu, sementara jumlah *false negative* yang masih cukup besar mengindikasikan bahwa ada ruang untuk perbaikan dalam hal sensitivitas model terhadap kasus positif. Dengan demikian, meskipun performa keseluruhan cukup baik, peningkatan *recall* atau penggunaan teknik penyeimbangan kelas dapat dipertimbangkan untuk meningkatkan deteksi terhadap pasien *diabetes*.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa pendekatan kombinasi antara *machine learning* dan *deep learning* dapat memberikan hasil yang akurat dalam memprediksi risiko *diabetes* berdasarkan data medis pasien. Dari lima model yang dibandingkan, *Multilayer Perceptron (MLP)* menghasilkan performa terbaik dengan akurasi, presisi, dan *recall* yang unggul dibandingkan model lainnya. Model *Random Forest* juga memberikan hasil yang sangat kompetitif, khususnya dalam kestabilan prediksi dan kerahasiaan pada data uji.

Proses *Preprocessing* data yang mencakup imputasi data hilang, *pengkodean* fitur kategorikal, *normalisasi*, dan pembagian data memberikan kontribusi besar terhadap keberhasilan model. Evaluasi dengan metrik akurasi, *presisi*, dan *recall* serta *visualisasi* seperti matriks konfusi dan kurva pembelajaran memberikan pemahaman mendalam terhadap performa dan *konvergensi* model selama pelatihan. Model *MLP* terbukti mampu menangani kompleksitas data dengan baik dan memiliki kemampuan *generalisasi* yang tinggi, meskipun membutuhkan sumber daya komputasi yang lebih besar. Sementara itu, model seperti *Regresi Logistik* dan *KNN* tetap relevan sebagai *baseline* yang sederhana dan cukup akurat. Penelitian ini dapat dijadikan dasar dalam pengembangan sistem prediksi medis yang efisien dan mendukung pengambilan keputusan klinis secara cepat dan berbasis data.

DAFTAR PUSTAKA

- [1] J. Informatika, D. Rekayasa, K. Jakakom, M. A. C, Z. Dwi, and R. Sari, "Penerapan Data Mining Untuk Prediksi Penyakit Diabetes Jurnal Informatika Dan Rekayasa Komputer (JAKAKOM)," vol. 4, no. April, pp. 827–834, 2024.
- [2] Y. H. Mahendra and R. Kusumawati, "Jurnal Computer Science and Information Technology (CoSciTech) Data Mining Analysis for Detecting Diabetes Mellitus Using Naïve Bayes," vol. 6, no. 1, pp. 39–44, 2025.
- [3] K. U. K. L. P. Enyakit, D. I. M. Elitus, S. T. K. Asus, and W. A. D. Esa, "P a k-n n (k-nn) k p d m s k : w d j," vol. 16, no. 2, pp. 133–142, 2022.
- [4] J. Singh, S. B. Goyal, R. K. Kaushal, N. Kumar, and S. S. Sehra, *Applied Data Science and Smart Systems*. 2024. doi: 10.1201/9781003471059.
- [5] N. Ulya, A. Zanetha, E. Sibuea, S. S. Purba, A. Ikka, and C. K. Herbawani, "Indonesia Diabetes," *J. Vol. 4, Nomor 3, Sept. 2023*, vol. 4, no. September, pp. 2332–2341, 2023.
- [6] A. R. Hidayat, H. Hanipah, A. Nurjanah, and R. Farizki, "Upaya untuk Mencegah Penyakit Diabetes pada Usia Dini," *J. Forum Kesehat. Media Publ. Kesehat. Ilm.*, vol. 11, no. 2, pp. 63–69, 2022, doi: 10.52263/jfk.v11i2.229.
- [7] F. N. Ikhromr, I. Sugiyarto, U. Faddillah, and B. Sudarsono, "Implementasi Data Mining Untuk Memprediksi Penyakit Diabetes Menggunakan Algoritma Naives Bayes dan K-Nearest Neighbor," *INTECOMS J. Inf. Technol. Comput. Sci.*, vol. 6, no. 1, pp. 416–428, 2023, doi: 10.31539/intecom.v6i1.5916.
- [8] A. Davinka Sembiring Depari, C. Cha Kirana, C. Nissa Oktariana, F. Akbar, and F. Fathoni, "Prediksi Risiko Diabetes Dengan Metode Naive Bayes: Identifikasi Faktor Risiko Utama Dan Evaluasi Akurasi Model," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 4, pp. 6372–6377, 2025, doi: 10.36040/jati.v9i4.14078.
- [9] D. C. P. Buani, "Deteksi Dini Penyakit Diabetes dengan Menggunakan Algoritma Random Forest," *EVOLUSI J. Sains dan Manaj.*, vol. 12, no. 1, pp. 1–8, 2024, doi: 10.31294/evolusi.v12i1.21005.
- [10] O. Y. Inonu and K. Magda, "Analisis Kinerja Algoritma Random Forest Dengan Model Machine Learning Pada Dataset Penyakit Diabetes," vol. 15, no. 1, pp. 1–7, 2025.
- [11] M. Fahmuddin, M. K. Aidid, and M. J. Taslim, "Implementasi Analisis Regresi Logistik Dengan Metode Machine Learning Untuk Mengklasifikasi Berita Di Indonesia," *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 5, no. 03, pp. 155–162, 2023, doi: 10.35580/variensium116.
- [12] M. Alidin *et al.*, "Jurnal Computer Science and Information Technology (CoSciTech) Application of K-Nearest Neighbors to the Classification of Legal Cases in the Federal Courts of," vol. 6, no. 1, pp. 85–93, 2025.
- [13] E. Stevens, *Deep learning with PyTorch*. 2021.
- [14] N. Nurussakinah and M. Faisal, "Klasifikasi Penyakit Diabetes Menggunakan Algoritma Decision Tree," *J. Inform.*, vol. 10, no. 2, pp. 143–149, 2023, doi: 10.31294/inf.v10i2.15989.
- [15] Suci Amaliah, M. Nusrang, and A. Aswi, "Penerapan Metode Random Forest Untuk Klasifikasi Varian Minuman Kopi di Kedai Kopi Konijiwa Bantaeng," *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 4, no. 3, pp. 121–127, 2022, doi: 10.35580/variensium31.