



## Implementasi Algoritma Jaringan Syaraf Tiruan *Backpropagation* untuk Prediksi Penyakit Diabetes

Alwi Syahputra<sup>1\*</sup>, Lailan Sofinah Harahap<sup>2</sup>

<sup>1-2</sup>Jurusan Ilmu Komputer, Universitas Islam Negeri Sumatera Utara, Indonesia

Email: [alwiisyahputra0@gmail.com](mailto:alwiisyahputra0@gmail.com)<sup>1\*</sup>, [lailansofinah@uinsu.ac.id](mailto:lailansofinah@uinsu.ac.id)<sup>2</sup>

\*Penulis Korespondensi: [alwiisyahputra0@gmail.com](mailto:alwiisyahputra0@gmail.com)

**Abstract.** *Diabetes Mellitus is a chronic disease characterized by impaired glucose metabolism and requires early detection to prevent serious complications such as cardiovascular disease, kidney failure, and nerve damage. The use of artificial intelligence technology is one potential approach to help the diagnosis process more quickly and accurately. This study aims to implement an Artificial Neural Network (ANN) algorithm with the Backpropagation method to predict the risk of diabetes based on patient clinical data. The dataset used is the Pima Indians Diabetes Dataset consisting of 768 medical records with eight feature attributes, including medical parameters such as glucose levels, blood pressure, and body mass index. The method used is a Multi-Layer Perceptron with an architecture of eight input neurons, two hidden layers, and one output neuron. Model performance evaluation was carried out using a Confusion Matrix to measure classification accuracy. The test results showed that the model was able to predict the diagnosis of diabetes with an accuracy level of 76.62%. Based on these results, it can be concluded that the Backpropagation algorithm is quite effective as an alternative method for early detection of diabetes, although further development is still needed to increase the sensitivity and accuracy of predictions in positive cases.*

**Keywords:** *Artificial Neural Network; Backpropagation; Diabetes Mellitus; Pima Indians Dataset; Prediction.*

**Abstrak.** Diabetes Melitus merupakan penyakit kronis yang ditandai dengan gangguan metabolisme glukosa dan memerlukan deteksi dini untuk mencegah komplikasi serius seperti penyakit kardiovaskular, gagal ginjal, dan kerusakan saraf. Pemanfaatan teknologi kecerdasan buatan menjadi salah satu pendekatan yang potensial dalam membantu proses diagnosis secara lebih cepat dan akurat. Penelitian ini bertujuan untuk mengimplementasikan algoritma Jaringan Syaraf Tiruan (JST) dengan metode Backpropagation guna memprediksi risiko penyakit diabetes berdasarkan data klinis pasien. Dataset yang digunakan adalah Pima Indians Diabetes Dataset yang terdiri dari 768 data rekam medis dengan delapan atribut fitur, meliputi parameter medis seperti kadar glukosa, tekanan darah, dan indeks massa tubuh. Metode yang digunakan adalah Multi-Layer Perceptron dengan arsitektur delapan neuron input, dua hidden layer, dan satu neuron output. Evaluasi performa model dilakukan menggunakan Confusion Matrix untuk mengukur akurasi klasifikasi. Hasil pengujian menunjukkan bahwa model mampu memprediksi diagnosis diabetes dengan tingkat akurasi sebesar 76,62%. Berdasarkan hasil tersebut, dapat disimpulkan bahwa algoritma Backpropagation cukup efektif sebagai metode alternatif untuk deteksi dini penyakit diabetes, meskipun pengembangan lebih lanjut masih diperlukan untuk meningkatkan sensitivitas dan ketepatan prediksi pada kasus positif.

**Kata kunci:** *Backpropagation; Diabetes Melitus; Jaringan Syaraf Tiruan; Pima Indians Dataset; Prediksi.*

### 1. LATAR BELAKANG

Diabetes melitus (DM) dikenal sebagai penyakit menahun yang muncul saat pankreas tidak mampu menghasilkan insulin dalam jumlah memadai, atau ketika insulin yang sudah diproduksi tidak bisa dimanfaatkan tubuh secara optimal. Padahal, insulin berperan penting dalam menjaga keseimbangan kadar gula di dalam darah. Jika diabetes tidak terkelola dengan baik, kondisi hiperglikemia atau lonjakan gula darah kerap terjadi dan dalam jangka panjang dapat menimbulkan kerusakan berat pada berbagai organ tubuh, terutama jaringan saraf serta pembuluh darah (Aminuddin et al., 2023).

Di Indonesia, pertumbuhan jumlah penyandang diabetes tergolong sangat tajam. Pada awal tahun 2000-an, penderitanya masih berada di kisaran jutaan orang, namun pada 2024 angkanya melonjak hingga melampaui 20 juta jiwa. Lonjakan ini tidak lepas dari semakin maraknya faktor pemicu, seperti perubahan pola hidup akibat urbanisasi dan kebiasaan hidup yang kurang sehat. Bahkan, pada 2019 Indonesia menduduki peringkat ketujuh dunia sebagai negara dengan jumlah penderita diabetes terbanyak, berada di bawah China, India, Amerika Serikat, Pakistan, Brasil, dan Meksiko, dengan total sekitar 10,7 juta penderita. Setahun kemudian, yakni pada 2020, jumlah tersebut kembali bertambah menjadi 10,8 juta orang dengan prevalensi mencapai 6,2%, dan diproyeksikan akan terus meningkat hingga menembus 16,7 juta penderita pada tahun 2045 (Erlin et al., 2022).

Diabetes yang tidak tertangani dengan baik berpotensi menimbulkan dampak lanjutan yang berat, mulai dari gangguan pada jantung, penurunan fungsi ginjal, kerusakan sistem saraf, hingga masalah pada penglihatan. Risiko munculnya komplikasi tersebut sebenarnya bisa ditekan apabila penyakit ini dikenali sejak awal dan ditangani dengan langkah yang tepat. Oleh karena itu, kegiatan skrining—terutama pemeriksaan kadar glukosa dalam darah—menjadi bagian krusial dalam upaya deteksi dini diabetes melitus. Edukasi serta cek gula darah sejak dini tidak hanya penting bagi orang yang sudah bergejala atau memiliki risiko tinggi, tetapi juga berperan dalam meningkatkan kesadaran masyarakat luas akan pentingnya menjaga kestabilan gula darah. Semakin banyak masyarakat yang paham risiko diabetes dan mulai menerapkan pola hidup sehat, peluang untuk mencegah serta menurunkan angka kejadian diabetes akan semakin besar (Singh, et al., 2024).

Neural Network (NN) atau yang dikenal sebagai Jaringan Saraf Tiruan (JST) merupakan pendekatan komputasi yang dirancang dengan meniru cara kerja otak manusia. Otak manusia sendiri tersusun atas jutaan unit pemroses kecil yang disebut neuron, yang saling terhubung dan bekerja secara bersamaan. Setiap neuron menerima masukan dari neuron lain, mengolah informasi tersebut, lalu meneruskan hasilnya ke neuron berikutnya untuk diproses lebih lanjut. Hubungan antarneuron ini bersifat dinamis dan membentuk jaringan yang sangat rumit. Berangkat dari konsep tersebut, berbagai model yang menyerupai mekanisme otak manusia dikembangkan dengan harapan mampu meniru kemampuan kognitif manusia, seperti mengingat, berhitung, melakukan generalisasi, serta beradaptasi terhadap lingkungan. Dengan mencontoh struktur dan alur kerja otak, JST diharapkan dapat mengambil alih sebagian tugas manusia, misalnya dalam pengenalan pola, prediksi, klasifikasi, pendekatan fungsi, hingga optimasi (Marwati & Fauzi, 2024).

Jaringan saraf tiruan juga dikenal sebagai salah satu paradigma komputasi yang terinspirasi dari sistem saraf makhluk cerdas, dengan tujuan memperoleh pengetahuan dari data secara lebih mendalam. Dalam praktiknya, JST banyak dimanfaatkan untuk berbagai kebutuhan komputasi, salah satunya adalah pengelompokan atau klasifikasi data penyakit (Alzboon, 2025). Terdapat beragam algoritma dalam JST yang digunakan untuk masalah klasifikasi, dan salah satu yang paling populer adalah algoritma Backpropagation Neural Network. Algoritma ini mampu belajar dari data sebelumnya sehingga dapat mengenali pola tertentu. Melalui proses pembelajaran tersebut, Backpropagation Neural Network dapat menganalisis serta mengklasifikasikan data dengan lebih baik, sekaligus menghasilkan estimasi yang relatif akurat karena adanya tahap pelatihan untuk mendapatkan model yang paling optimal (Cahyani et al., 2025).

Sejumlah penelitian mutakhir telah menunjukkan bahwa penggunaan JST cukup efektif dalam membantu proses diagnosis di bidang kesehatan. Studi yang dilakukan oleh Efendi (2025) membuktikan bahwa penerapan teknik optimasi Grid Search pada algoritma Backpropagation mampu meningkatkan ketepatan prediksi diabetes secara signifikan dibandingkan pendekatan konvensional. Penelitian lain oleh Guswanti et al., (2024) yang membandingkan metode inisialisasi bobot pada JST menyimpulkan bahwa penyesuaian parameter tertentu dapat mempercepat proses konvergensi model dalam mengklasifikasikan pasien diabetes. Sementara itu, penelitian yang dipublikasikan dalam prosiding nasional oleh Nisa et al., (2025) menerapkan JST pada dataset Pima Indians dan menemukan bahwa pemilihan arsitektur jaringan yang sesuai dapat menekan tingkat kesalahan selama proses pelatihan. Salah satu teknik klasifikasi yang paling sering digunakan dalam riset diagnosis penyakit adalah Backpropagation Neural Network (BPNN), yang merupakan bagian dari model Multi-Layer Perceptron (MLP). Penelitian oleh Nurhadi, Defit, dan Nurcahyo pada tahun 2025 yang memanfaatkan MLP untuk mengidentifikasi demam dengue dan tifus berhasil mencapai tingkat akurasi sebesar 98,68% dengan pembagian data 70:30 (Nurhadi et al., 2025).

Bertolak dari uraian tersebut, penelitian ini diarahkan untuk menerapkan sekaligus menguji tingkat akurasi algoritma Jaringan Saraf Tiruan Backpropagation dalam memprediksi penyakit diabetes. Data yang digunakan berasal dari Pima Indians Diabetes Dataset yang tersedia di repositori publik seperti Kaggle atau UCI. Dataset ini memuat 768 catatan medis dengan delapan atribut utama, yaitu jumlah kehamilan, kadar glukosa, tekanan darah, ketebalan lipatan kulit, kadar insulin, indeks massa tubuh (BMI), riwayat diabetes dalam keluarga (pedigree function), serta usia. Melalui penelitian ini, diharapkan dapat dihasilkan model

deteksi dini diabetes yang tidak hanya akurat, tetapi juga efisien dan mudah dikembangkan lebih lanjut.

## 2. KAJIAN TEORITIS

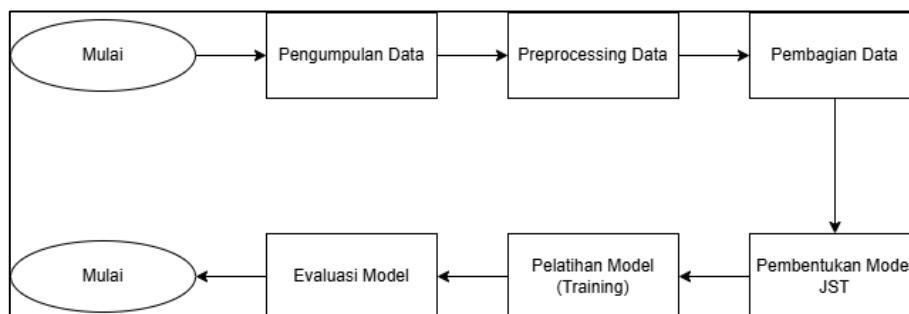
Penyakit diabetes muncul karena ketidakmampuan tubuh mengelola insulin sehingga memicu lonjakan gula darah yang berujung pada komplikasi serius (Efendi, 2025). Pencegahan kondisi ini sangat bergantung pada deteksi dini yang kini makin canggih berkat dukungan teknologi komputasi. Salah satu pendekatan utamanya menggunakan Jaringan Syaraf Tiruan yang didesain meniru struktur neuron otak untuk memproses informasi (Wardhana, 2024).

Sistem ini memiliki kemampuan belajar adaptif terutama jika menggunakan algoritma Backpropagation yang bisa meminimalkan kesalahan prediksi secara berulang. Validasi modelnya sering memanfaatkan Dataset Pima Indians Diabetes karena memuat variabel numerik yang relevan seperti tekanan darah serta riwayat keluarga (Guswanti et al., 2025).

Penggunaan JST dalam konteks ini menawarkan solusi deteksi otomatis yang mampu membaca hubungan antar variabel yang rumit (Zaferani, 2025). Model ini sangat efektif sebagai alat skrining awal untuk memilah individu berisiko tinggi. Namun demikian hasil analisis komputer ini tidak menggantikan peran diagnosis medis melainkan berfungsi sebagai opini kedua atau pendukung keputusan klinis (Cahyani et al., 2025).

## 3. METODE PENELITIAN

Alur penelitian dirancang secara sistematis untuk memastikan model Jaringan Syaraf Tiruan dapat bekerja optimal. Rincian tahapan yang dilakukan adalah sebagai berikut:



**Gambar 1.** Alur Penelitian.

Tahap awal penelitian dimulai dengan pengumpulan data sekunder, yaitu Pima Indians Diabetes Dataset. Data ini diambil dari repositori publik dan berisi 768 rekam medis pasien dengan 8 variabel independen (seperti kadar glukosa, tekanan darah, usia) dan 1 variabel dependen (diagnosis diabetes). Penelitian ini menggunakan dataset sekunder Pima Indians Diabetes Dataset yang bersumber dari National Institute of Diabetes and Digestive and Kidney

Diseases melalui repositori publik. Dataset ini dipilih karena memiliki integritas data yang baik dan telah banyak digunakan sebagai standar dalam pengujian algoritma machine learning. Data terdiri dari 768 sampel dengan format numerik, yang mencakup parameter klinis seperti kadar glukosa, tekanan darah, indeks massa tubuh, hingga riwayat genetik keluarga.

**Tabel 1.** Daftar Atribut Pada Dataset.

No	Atribut	Keterangan
1	Pregnancies	Jumlah kehamilan
2	Glucose	Konsentrasi glukosa plasma 2 jam
3	BloodPressure	Tekanan darah diastolik (mm Hg)
4	SkinThickness	Ketebalan lipatan kulit triceps (mm)
5	Insulin	Insulin serum 2 jam (mu U/ml)
6	BMI	Indeks massa tubuh
7	DiabetesPedigreeFunction	Riwayat diabetes dalam keluarga
8	Age	Umur (tahun)
9	Outcome	Target (0 = Negatif, 1 = Positif)

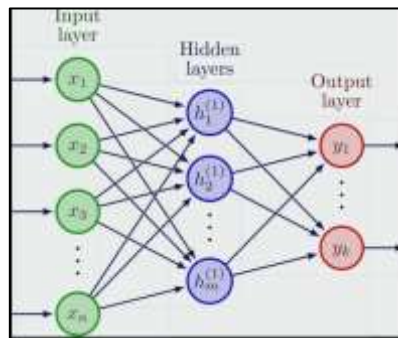
Tahap Pre-Processing atau tahap pra-pemrosesan adalah langkah penting dalam mengkaji data yang akan digunakan, dengan tujuan untuk mengoptimalkan hasil yang diperoleh (Artanti, 2023). Lengkap atau memiliki format yang bervariasi. Oleh karena itu, tahap ini sangat krusial dan terdiri dari dua sub-proses: 1) Penangan nilai hilang (Imputation): Beberapa kolom seperti Glukosa, Tekanan Darah, dan Ketebalan Kulit memiliki nilai 0 yang tidak valid secara medis. Menghapus data tersebut akan mengurangi jumlah informasi secara signifikan. Oleh karena itu, teknik imputasi diterapkan dengan mengganti nilai 0 tersebut menggunakan nilai rata-rata (mean) dari masing-masing atribut, sehingga distribusi data tetap terjaga. 2) Normalisasi Data (Normalization): Jaringan Syaraf Tiruan sensitif terhadap skala data input. Data dengan rentang besar (seperti Insulin: 0-846) akan mendominasi perhitungan bobot dibandingkan data rentang kecil (seperti DiabetesPedigree: 0.07-2.42). Untuk mengatasi ini, dilakukan normalisasi Min – Max Scaler untuk mentransformasi seluruh data ke dalam rentang [0, 1]. Normalisasi data sangat penting dalam algoritma berbasis gradien seperti Backpropagation untuk mempercepat konvergensi pelatihan. Persamaan normalisasi yang digunakan adalah:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Dimana  $x'$  adalah hasil data normalisasi,  $x$  adalah data asli,  $x_{min}$  adalah nilai terendah, dan  $x_{max}$  adalah nilai tertinggi dalam fitur tersebut.

Untuk mengukur kinerja model secara objektif, dataset tidak boleh digunakan seluruhnya untuk melatih model. Data dibagi menggunakan teknik Hold-out Validation dengan rasio 80:20: 1) Data Latih (80%): Sebanyak 614 data digunakan oleh algoritma untuk mempelajari pola hubungan antara fitur input dan label diabetes, serta untuk memperbarui bobot jaringan. 2) Data Uji (20%): Sebanyak 154 data dipisahkan dan "disembunyikan" saat pelatihan. Data

ini hanya digunakan di tahap akhir untuk menguji seberapa akurat model dalam memprediksi kasus baru yang belum pernah dikenali sebelumnya.



**Gambar 2.** Algoritma JST Backpropagation.

Model dibangun menggunakan algoritma *Backpropagation* dengan arsitektur *Multi-Layer Perceptron* (MLP). Struktur jaringan terdiri dari: 1) Input Layer: Terdiri dari 8 neuron yang merepresentasikan 8 variabel independen. 2) Hidden Layer: Menggunakan fungsi aktivasi ReLU (*Rectified Linear Unit*). Fungsi ini dipilih karena komputasinya yang efisien dan mampu mengatasi masalah *vanishing gradient* pada saat pelatihan. 3) Output Layer: Terdiri dari 1 neuron dengan fungsi aktivasi Sigmoid. Fungsi Sigmoid digunakan karena output yang diharapkan adalah probabilitas biner (antara 0 dan 1), sesuai dengan persamaan:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

Jika nilai output  $> 0.5$ , maka diklasifikasikan sebagai Diabetes (1), dan sebaliknya dianggap Normal (0).

Proses pelatihan dilakukan menggunakan optimizer Adam (Adaptive Moment Estimation) yang bertugas memperbarui bobot jaringan secara iteratif untuk meminimalkan nilai loss atau error. Setelah model terbentuk, evaluasi dilakukan menggunakan Confusion Matrix. Dari matriks ini, dihitung nilai Akurasi (Accuracy) untuk melihat persentase keberhasilan model dalam mengklasifikasikan pasien positif dan negatif secara tepat.

## 4. HASIL DAN PEMBAHASAN

### Skenario Pengujian Arsitektur Jaringan

Sebelum menetapkan model terbaik, penelitian ini melakukan beberapa skenario pengujian untuk mencari kombinasi hyperparameter yang paling optimal. Pengujian dilakukan dengan memvariasikan jumlah neuron pada hidden layer dan nilai learning rate. Variasi ini bertujuan untuk melihat pengaruh kompleksitas jaringan terhadap kemampuan model dalam mengenali pola diabetes.

Tiga model arsitektur diuji dengan konfigurasi sebagai berikut:

- a) Model A: 1 Hidden Layer (8 neuron).
- b) Model B: 2 Hidden Layer (12 neuron & 8 neuron).
- c) Model C: 2 Hidden Layer (16 neuron & 8 neuron) dengan learning rate 0.001.

Hasil perbandingan akurasi dari ketiga model tersebut disajikan pada Tabel 2.

**Tabel 2.** Akurasi dari model arsitektur.

Model	Konfigurasi Hidden Layer	Epoch	Akurasi Training	Akurasi Testing
Model A	(8 Neuron)	100	74.20%	72.08%
Model B	(12 Neuron & 8 Neuron)	150	78.50%	76.62%
Model C	(16 Neuron & 8 Neuron)	150	79.10%	75.32%

Berdasarkan Tabel 2, Model B dipilih sebagai model terbaik karena menghasilkan akurasi *testing* tertinggi (76.62%) dengan kestabilan yang baik antara data latih dan data uji. Model C, meskipun memiliki neuron lebih banyak, mengalami indikasi *overfitting* dimana akurasi *training* tinggi namun akurasi *testing* justru menurun. Oleh karena itu, pembahasan selanjutnya akan berfokus pada hasil evaluasi Model B.

### Evaluasi Kinerja Model (Confusion Matrix)

Evaluasi mendalam dilakukan menggunakan Confusion Matrix untuk mengukur seberapa baik model mengklasifikasikan kelas positif (Diabetes) dan negatif (Sehat). Matriks hasil prediksi pada data uji (154 sampel) ditampilkan pada Tabel 3.

**Tabel 3.** Hasil prediksi data uji.

Prediksi: Sehat (0)	Prediksi: Diabetes (1)
86 (TN)	23 (FN)
13 (FP)	32 (TP)

Berdasarkan nilai pada Tabel 3, kinerja model tidak hanya diukur dari Akurasi, tetapi juga dari nilai Precision, Recall, dan F1-Score untuk memastikan model tidak bias ke salah satu kelas. Perhitungan dilakukan sebagai berikut:

1. Akurasi (Accuracy): Tingkat kebenaran prediksi secara keseluruhan.

$$Akurasi = \frac{TP+TN}{Total} = \frac{32+86}{154} = \frac{118}{154} = 76.62\% \quad (3)$$

2. Presisi (Precision): Seberapa kuat akurat model saat memprediksi seseorang menderita diabetes.

$$Precision = \frac{TP}{TP+FP} = \frac{32}{32+13} = 71.11\% \quad (4)$$

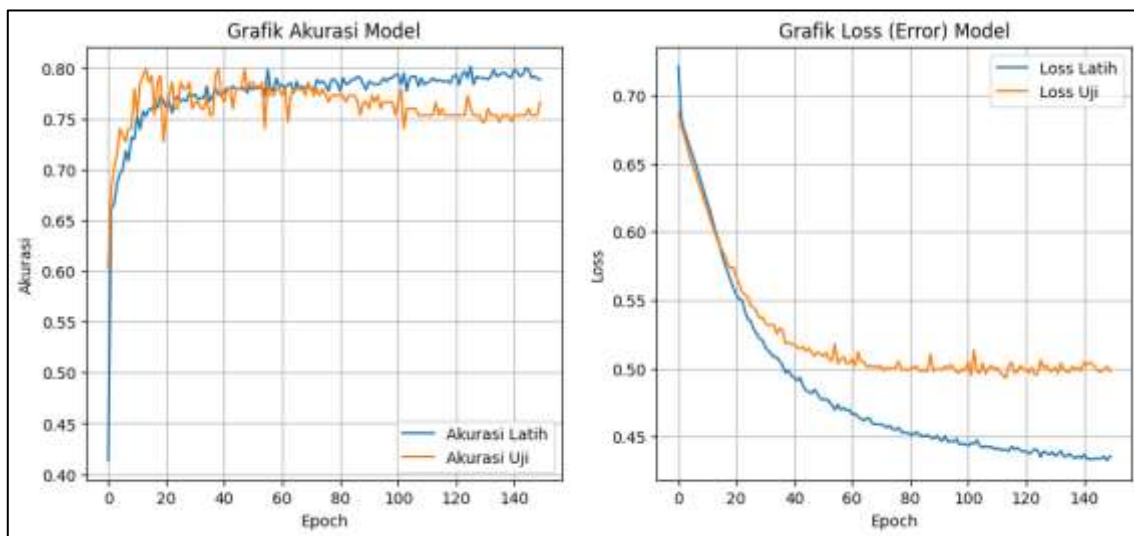
3. Sensitivitas (Recall): Kemampuan model mendeteksi seluruh pasien yang sebenarnya menderita diabetes.

$$Recall = \frac{TP}{TP+FN} = \frac{32}{32+23} = 58.18\% \quad (5)$$

Hasil perhitungan menunjukkan bahwa model memiliki spesifisitas yang sangat baik dalam mengenali orang sehat ( $TN=86$ ), namun nilai *Recall* sebesar 58.18% menunjukkan bahwa masih ada tantangan dalam mendeteksi pasien diabetes yang memiliki gejala samar (*False Negative* = 23).

### Analisis Grafik Pelatihan (Training History)

Proses pembelajaran model direkam dalam bentuk grafik perubahan loss dan accuracy di setiap epoch (perulangan).



**Gambar 3** Grafik Loss dan Akurasi Selama 150 Epoch.

Pada Gambar 3, garis biru merepresentasikan data latih dan garis oranye merepresentasikan data uji. Terlihat bahwa pada awal pelatihan (epoch 0-20), grafik loss menurun tajam, yang menandakan model sedang belajar fitur-fitur utama data secara cepat. Memasuki epoch ke-100 hingga 150, grafik mulai landai (konvergen), yang berarti model telah mencapai titik optimalnya. Jarak yang sempit antara garis akurasi latih dan uji menunjukkan bahwa model memiliki kemampuan generalisasi yang baik (Good Fit) dan tidak mengalami overfitting yang parah.

Hasil akurasi 76.62% yang diperoleh dalam penelitian ini sejalan dengan rentang rata-rata penelitian terdahulu pada dataset *Pima Indians*, yang umumnya berkisar antara 75% hingga 80%. Algoritma *Backpropagation* dengan optimasi *Adam* terbukti mampu menangani data medis yang memiliki *noise* (seperti nilai 0 pada glukosa yang telah diimputasi).

Namun, terdapat 23 kasus *False Negative* (pasien diabetes diprediksi sehat). Analisis lebih lanjut menduga hal ini disebabkan oleh kemiripan fitur BMI dan Glukosa pada pasien diabetes tahap awal dengan pasien sehat, sehingga model kesulitan membedakannya. Untuk penelitian selanjutnya, disarankan menggunakan teknik *Feature Selection* atau menyeimbangkan jumlah data kelas (SMOTE) untuk meningkatkan nilai *Recall*.

## 5. KESIMPULAN DAN SARAN

Berdasarkan pengujian yang telah dilakukan ternyata algoritma JST Backpropagation sukses diterapkan untuk memprediksi risiko diabetes menggunakan dataset Pima Indians. Model paling optimal ditemukan pada arsitektur Multi-Layer Perceptron dengan susunan 8 neuron input lalu dua *hidden layer* berisi 12 dan 8 neuron serta satu neuron output. Evaluasi kinerja lewat Confusion Matrix menunjukkan akurasi mencapai 76.62% yang berarti sistem cukup andal membedakan pasien diabetes maupun non-diabetes. Namun tantangan muncul pada nilai sensitivitas yang berada di angka 58.18% karena sistem masih kesulitan mendeteksi pasien positif dengan gejala samar. Artinya metode ini sangat efektif sebagai alat *screening* awal tetapi pemeriksaan medis lanjutan tetap wajib dilakukan.

Penelitian ini tentu masih memiliki celah yang bisa disempurnakan pada studi berikutnya agar hasilnya lebih maksimal. Langkah pertama yang bisa dicoba adalah menerapkan teknik *Resampling* semacam SMOTE untuk menyeimbangkan data kelas positif maupun negatif demi mendongkrak nilai *Recall*. Upaya ini penting agar kesalahan deteksi pada pasien positif bisa ditekan seminimal mungkin. Selain itu penggunaan metode seleksi fitur seperti PCA atau matriks korelasi juga sangat disarankan untuk memangkas atribut yang tidak relevan sehingga proses pelatihan jadi lebih efisien. Terakhir ada baiknya membandingkan kinerja JST dengan algoritma lain semisal SVM atau *Random Forest* untuk menemukan metode yang paling tangguh untuk dataset ini.

## DAFTAR REFERENSI

- Alzboon, M. S. (2025). *Diabetes prediction and management using machine learning algorithms* [Preprint]. arXiv. <https://arxiv.org/abs/2506.11501>
- Aminuddin, A., Sima, Y., Izza, N. C., Norma, N. S., & Arda, D. (2023). Edukasi kesehatan tentang penyakit diabetes melitus bagi masyarakat. *Jurnal Pengabdian kepada Masyarakat*, 2(1), 7–12. <https://doi.org/10.35816/abdimaspolsaka.v2i1.25>
- Artanti, P. H. (2023). *Penerapan neural network dengan optimasi ant colony optimization dan backpropagation untuk membangun model prediksi diabetes tahap awal* [Tesis]. Universitas Islam Negeri Maulana Malik Ibrahim. <http://etheses.uin-malang.ac.id/59735/7/19650090.pdf>
- Cahyani, N., Irsyada, R., & Mahmuda, R. (2025). Penerapan algoritma neural network untuk klasifikasi diabetes mellitus: Perbandingan backpropagation dan resilient backpropagation. *Digital Transformation Technology*, 4(2), 1067–1074. <https://doi.org/10.47709/digitech.v4i2.5208>

- Cahyani, N., Irsyada, R., & Mahmuda, R. (2025). Penerapan algoritma neural network untuk klasifikasi diabetes mellitus: Perbandingan backpropagation dan resilient backpropagation. *Digital Transformation Technology*, 4(2), 1067–1074. <https://doi.org/10.47709/digitech.v4i2.5208>
- Efendi, D. F. (2025). Peningkatan akurasi pada backpropagation dengan teknik grid search terhadap prediksi diabetes mellitus. *Jurnal Penelitian Ilmu Komputer*, 3(2), 33–38.
- Efendi, D. F. (2025). Peningkatan akurasi pada backpropagation dengan teknik grid search terhadap prediksi diabetes mellitus. *Jurnal Penelitian Ilmu Komputer*, 3(2), 33–38. <https://jpilkom.org/index.php/journal/article/view/81>
- Erlin, Marlim, Y. N., Junadhi, Suryati, L., & Agustina, N. (2022). Deteksi dini penyakit diabetes menggunakan machine learning dengan algoritma logistic regression. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 11(2), 88–96.
- Guswanti, W., Afrianty, I., Budianita, E., & Syafria, F. (2024). Perbandingan inisialisasi bobot random dan Nguyen-Widrow pada backpropagation dalam klasifikasi penyakit diabetes. *Jurnal Informatika (Jurnal Pengembangan IT)*, 9(2).
- Guswanti, W., Afrianty, I., Budianita, E., & Syafria, F. (2025). Perbandingan inisialisasi bobot random dan Nguyen-Widrow pada backpropagation dalam klasifikasi penyakit diabetes. *Jurnal Informatika*, 9(2). <https://ejournal.poltekharber.ac.id/index.php/informatika/article/view/8618>
- Marwati, F., & Fauzi, R. (2024). Prediksi penyakit diabetes melitus menggunakan jaringan syaraf tiruan dengan metode backpropagation. *Jurnal Informatika Utama*, 2(1), 26–34. <https://doi.org/10.55903/jitu.v2i1.163>
- Nisa, N. K., Sani, D. A., & Udin, M. (2025). Prediksi dini resiko penyakit diabetes menggunakan jaringan syaraf tiruan backpropagation. *Jurnal Mahasiswa Teknik Informatika*, 9(5), 9096–9102. <https://doi.org/10.36040/jati.v9i5.15134>
- Nurhadi, N., Defit, S., & Nurcahyo, G. W. (2025). Model deep learning berbasis multilayer perceptron untuk identifikasi demam berdarah dengue dan tifus. *Bulletin of Computer Science Research*, 5(5), 1095–1102. <https://doi.org/10.47065/bulletincsr.v5i5.754>
- Singh, A., Destra, E., Kurniawan, J., Suros, A. S., Febriastuti, A., & Sitorus, R. A. H. (2024). Kegiatan deteksi dini penyakit diabetes mellitus tipe 2 melalui pemeriksaan gula darah sewaktu pada kelompok usia produktif. *Jurnal Pengabdian Masyarakat*, 3(1), 207–213. <https://doi.org/10.30640/abdimas45.v3i1.2986>
- Wardhana, F. K. (2024). Penerapan backpropagation jaringan saraf tiruan untuk prediksi diabetes menggunakan dataset Pima Indians. *Seminar Nasional Sains dan Aplikasi*, 4. <https://ojs.amikomsolo.ac.id/index.php/semnasa/article/view/485>
- Zaferani, N. (2025). Predicting and classifying type 2 diabetes using a hybrid machine learning model. *Scientific Reports*. <https://doi.org/10.1038/s41598-025-31562-5>