

Deteksi Dini Hipertensi pada Usia Dewasa Menggunakan Deep Neural Network Berdasarkan Data Skrining Kesehatan

Sofiah Baiti Auliyah, Dian Ahkam Sani, M. Udin

Teknik Informatika, Teknologi Informasi, Universitas Merdeka Pasuruan

Email: Sofiahbaity24@gmail.com, dian.ahkam@unmerpas.ac.id, imelekacong28@gmail.com

Diajukan: 27-06-2026 Direvisi: 21-08-2026	Disetujui: 07-09-2026 Diterbitkan: 30-09-2026
Abstract. Hypertension is one of the non-communicable diseases that often develops without obvious symptoms, causing many patients to realize their condition only after complications occur. Therefore, an early detection system is needed to assist health workers in identifying hypertension risk based on health screening data. This study aims to develop an early hypertension detection model using the Deep Neural Network (DNN) method. The dataset consisted of 214 adult health screening records obtained from the Posyandu in Tebas Village, Gondangwetan District, Pasuruan Regency. The input variables included gender, age, body weight, height, waist circumference, systolic blood pressure, and diastolic blood pressure, while the output variable was hypertension status. Data preprocessing included data cleaning, label encoding, feature standardization using StandardScaler, and dataset splitting with a ratio of 80% for training data and 20% for testing data. The DNN architecture consisted of three hidden layers with ReLU activation, Sigmoid activation in the output layer, Adam optimizer, Binary Crossentropy loss function, and Early Stopping to reduce overfitting. Experimental results showed that the proposed model achieved an accuracy of 88.37% on the testing dataset with a precision of 94%, recall of 91%, and F1-score of 93% for the hypertension class. These results indicate that the Deep Neural Network model performs well in classifying hypertension risk and has the potential to support early hypertension screening. Keywords: Classification, Deep Learning, Deep Neural Network, Hypertension, Health Screening Abstrak. Hipertensi merupakan salah satu penyakit tidak menular yang sering berkembang tanpa gejala yang jelas sehingga banyak penderita baru mengetahui kondisinya setelah terjadi komplikasi. Oleh karena itu, diperlukan suatu sistem yang mampu membantu proses deteksi dini berdasarkan data skrining kesehatan. Penelitian ini bertujuan membangun model deteksi dini hipertensi menggunakan metode Deep Neural Network (DNN). Dataset yang digunakan berjumlah 214 data hasil skrining kesehatan masyarakat usia dewasa di Posyandu Desa Tebas, Kecamatan Gondangwetan, Kabupaten Pasuruan. Variabel masukan terdiri atas jenis kelamin, usia, berat badan, tinggi badan, lingkar perut, tekanan darah sistolik, dan tekanan darah diastolik, sedangkan variabel keluaran berupa status hipertensi. Tahapan penelitian meliputi pembersihan data, transformasi data kategorikal menggunakan label encoding, standarisasi data menggunakan StandardScaler, serta pembagian data menjadi 80% data training dan 20% data testing. Model DNN dibangun menggunakan tiga hidden layer dengan fungsi aktivasi ReLU, fungsi aktivasi Sigmoid pada output layer, optimizer Adam, fungsi loss Binary Crossentropy, serta Early Stopping untuk mengurangi overfitting. Hasil pengujian menunjukkan bahwa model memperoleh akurasi sebesar 88,37% pada data testing dengan nilai precision sebesar 94%, recall sebesar 91%, dan F1-score sebesar 93% pada kelas hipertensi. Hasil tersebut menunjukkan bahwa metode	

Deep Neural Network mampu memberikan performa yang baik dalam mendukung proses deteksi dini hipertensi berdasarkan data skrining kesehatan.

Kata Kunci: *Deep Learning, Deep Neural Network, Hipertensi, Klasifikasi, Skrining Kesehatan*

1. Pendahuluan

Hipertensi merupakan salah satu penyakit tidak menular yang menjadi masalah kesehatan masyarakat karena prevalensinya terus meningkat setiap tahun. Penyakit ini dikenal sebagai *silent killer* karena pada tahap awal umumnya tidak menimbulkan gejala yang jelas sehingga banyak penderita baru mengetahui dirinya mengalami hipertensi setelah terjadi komplikasi. Hipertensi menjadi salah satu faktor risiko utama terhadap penyakit jantung, stroke, gagal ginjal, serta berbagai penyakit kardiovaskular lainnya. Oleh karena itu, upaya deteksi dini sangat diperlukan untuk menekan angka kesakitan dan mencegah terjadinya komplikasi yang lebih serius (Kementerian Kesehatan Republik Indonesia, 2023).

Salah satu upaya yang dapat dilakukan untuk mendukung deteksi dini hipertensi adalah melalui kegiatan skrining kesehatan. Data hasil skrining seperti usia, jenis kelamin, berat badan, tinggi badan, lingkar perut, tekanan darah sistolik, dan tekanan darah diastolik dapat dimanfaatkan untuk mengidentifikasi risiko hipertensi seseorang. Namun, jumlah data skrining yang terus bertambah menyebabkan proses analisis secara manual menjadi kurang efektif dan membutuhkan waktu yang relatif lama. Oleh karena itu, diperlukan suatu metode komputasi yang mampu mengenali pola hubungan antarvariabel secara cepat, tepat, dan akurat untuk membantu proses klasifikasi status hipertensi (Santoni et al., 2020).

Perkembangan teknologi *Artificial Intelligence* (AI), khususnya *Machine Learning* dan *Deep Learning*, telah memberikan kontribusi yang besar dalam bidang kesehatan. Salah satu metode *Deep Learning* yang banyak digunakan adalah *Deep Neural Network* (DNN), yaitu jaringan saraf tiruan yang memiliki beberapa *hidden layer* sehingga mampu mempelajari hubungan nonlinier yang kompleks dari suatu dataset. Kemampuan tersebut menjadikan DNN banyak diterapkan dalam berbagai penelitian klasifikasi maupun prediksi penyakit karena mampu menghasilkan performa yang lebih baik dibandingkan beberapa metode klasifikasi konvensional pada data yang kompleks (Sutriawan et al., 2023).

Beberapa penelitian terdahulu telah menerapkan metode klasifikasi untuk mendeteksi hipertensi. Santoni et al. (2020) membandingkan metode Decision Tree, Naïve Bayes, dan Artificial Neural Network dalam klasifikasi hipertensi. Hasil penelitian menunjukkan bahwa metode Artificial Neural Network mampu memberikan performa yang lebih baik dibandingkan metode lainnya. Selanjutnya, Khairunnisa (2025) menerapkan metode *Backpropagation Neural Network* pada klasifikasi hipertensi menggunakan data rekam medis pasien dan menunjukkan bahwa jaringan saraf tiruan mampu memberikan hasil klasifikasi yang baik berdasarkan kombinasi parameter pelatihan yang digunakan. Selain itu, Yun et al. (2023) mengembangkan model berbasis *Deep Learning* menggunakan *Temporal Fusion Transformer* untuk memprediksi hipertensi dan memperoleh nilai AUROC sebesar 0,953. Hasil penelitian-penelitian tersebut menunjukkan bahwa metode berbasis *Deep Learning* memiliki potensi yang baik dalam meningkatkan akurasi deteksi hipertensi.

Meskipun demikian, sebagian besar penelitian terdahulu masih menggunakan data rekam medis rumah sakit atau dataset sekunder sebagai sumber data penelitian. Sementara itu, penelitian yang memanfaatkan data skrining kesehatan masyarakat di tingkat posyandu dengan

implementasi metode Deep Neural Network masih relatif terbatas. Padahal, data skrining kesehatan masyarakat memiliki potensi yang besar sebagai dasar deteksi dini hipertensi karena diperoleh langsung dari kegiatan pelayanan kesehatan di masyarakat.

Berdasarkan permasalahan tersebut, penelitian ini mengimplementasikan metode Deep Neural Network (DNN) untuk melakukan klasifikasi status hipertensi menggunakan data skrining kesehatan masyarakat usia dewasa yang diperoleh dari Posyandu Desa Tebas, Kecamatan Gondangwetan, Kabupaten Pasuruan. Dataset penelitian terdiri atas 214 data responden yang diproses melalui tahapan *data preprocessing*, *Label Encoding*, standardisasi menggunakan *StandardScaler*, serta pembagian data menjadi data *training* dan *testing*. Model kemudian dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengetahui kemampuan model dalam mendukung proses deteksi dini hipertensi. Hasil penelitian ini diharapkan dapat memberikan alternatif metode yang efektif dalam membantu proses deteksi dini hipertensi berdasarkan data skrining kesehatan masyarakat.

2. Tinjauan Pustaka

2.1 Penelitian Terdahulu

Sejumlah penelitian terdahulu telah menguji efektivitas algoritma komputasi untuk mendiagnosis penyakit kardiovaskular. Penelitian oleh Kurniawan dkk. (2023) menggunakan algoritma Regresi Logistik untuk memprediksi risiko hipertensi pada populasi dewasa di Indonesia dan memperoleh akurasi sebesar 89,6% dengan nilai AUC 0,829. Bisong dkk. (2024) memprediksi tekanan darah tinggi di 57 negara menggunakan variabel demografi dan fisik dengan capaian akurasi tertinggi sebesar 81,41%. Omankwu dkk. (2024) membuktikan bahwa penggunaan model *Deep Learning Neural Network* memberikan akurasi yang lebih tinggi dan stabil dibandingkan metode konvensional seperti KNN dan SVM dalam menganalisis kompleksitas data medis jantung. Sementara itu, Santoni dkk. (2020) menguji metode Naive Bayes untuk klasifikasi hipertensi dan memperoleh akurasi sebesar 82,5%. Penelitian-penelitian tersebut memperkuat argumen bahwa pemanfaatan jaringan saraf dalam (*Deep Neural Network*) sangat relevan dan andal untuk mengolah data kesehatan secara optimal.

2.2 Hipertensi

Kondisi medis kronis yang ditandai dengan peningkatan tekanan darah di atas batas normal. Seseorang dikategorikan mengidap hipertensi apabila tekanan darah sistoliknya ≥ 140 mmHg dan/atau tekanan darah diastoliknya ≥ 90 mmHg. Faktor risikonya terbagi menjadi faktor yang tidak dapat dimodifikasi (usia, jenis kelamin, genetik) dan faktor yang dapat dimodifikasi (obesitas, merokok, konsumsi garam berlebih, dan kurang aktivitas fisik).

2.3 Skrining Kesehatan

Serangkaian pemeriksaan cepat untuk mengevaluasi status kesehatan atau mendeteksi kelainan medis tertentu sebelum munculnya gejala klinis yang nyata pada kelompok masyarakat.

2.4 Deep Neural Network (DNN)

Jaringan saraf tiruan yang memiliki lebih dari satu *hidden layer* di antara input dan output layer. Struktur berlapis ini memungkinkan DNN mempelajari representasi data

berdimensi tinggi serta menghasilkan tingkat akurasi prediksi yang kompetitif pada data kesehatan yang kompleks.


2.5 Python

Bahasa pemrograman tingkat tinggi yang bersifat *open-source* dan populer dalam pengembangan model AI. Framework pendukung seperti Pandas, NumPy, Scikit-learn, TensorFlow, dan Keras sangat membantu dalam efisiensi pengolahan data serta pelatihan model deep learning.

3. Metode Penelitian

3.1 Alur Penelitian

Tahap penelitian ini mencakup serangkaian langkah sistematis mulai dari analisis kebutuhan awal, pengumpulan data, hingga pemrosesan awal (pre-processing) guna memastikan kualitas serta keakuratan data sebelum diuji menggunakan model sistem cerdas yang dibangun. Alur pelaksanaan tahapan penelitian ini digambarkan secara skematis pada Gambar 1 berikut:



Gambar 1 Alur Penelitian

3.1.1 Identifikasi dan Pengumpulan Data

Penelitian difokuskan pada pemanfaatan data skrining kesehatan usia dewasa (18–60 tahun) yang diperoleh dari Posyandu Desa Tebas, Kecamatan Gondangwetan, Kabupaten Pasuruan. Algoritma DNN dipilih karena ketepatannya dalam memproses pola data medis yang kompleks. Total Sampel: 214 data responden. Variabel Input (Fitur): Jenis kelamin, usia, berat badan, tinggi badan, lingkar perut, tekanan darah sistolik, dan tekanan darah diastolik. Variabel Output (Target): Status kesehatan (dikategorikan "Hipertensi" jika sistolik ≥ 140 mmHg atau diastolik ≥ 90 mmHg, dan "Normal" jika di bawah batas tersebut).

3.2 Dataset dan Praproses Data (Preprocessing)

Dataset yang digunakan dalam penelitian ini berjumlah 214 data responden dewasa. Atribut input yang digunakan meliputi: jenis kelamin, usia (rentang 18–60 tahun), berat badan (BB), tinggi badan (TB), lingkar perut (LP), tekanan darah sistolik, dan tekanan darah diastolik. Variabel output-nya adalah status kesehatan yang diklasifikasikan menjadi dua kelas: Normal dan Hipertensi.

Sebelum dimasukkan ke dalam model DNN, data melalui proses preprocessing berikut:

- Pembersihan Data: Memeriksa data yang hilang (*missing values*). Hasil pemeriksaan menunjukkan seluruh baris data terisi penuh tanpa data kosong.
- Transformasi Kategorikal: Mengubah variabel non-numerik seperti jenis kelamin menjadi representasi angka digital.
- Standardisasi Nilai: Mengingat rentang angka antar-atribut memiliki skala yang berbeda (misalnya nilai usia dengan tekanan darah), dilakukan standardisasi

menggunakan rumus *StandardScaler* agar proses konvergensi model menjadi lebih stabil dan optimal:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

Keterangan:

- z = nilai hasil standardisasi
- x = nilai data asli
- μ = nilai rata-rata
- σ = standar deviasi

3.3 Pembagian Dataset

Dataset dibagi menjadi 2 Data Trening dan Data Testing diantaranya:

- a. Data trining Sebanyak 80 data (80%) digunakan sebagai data training. Data training berfungsi untuk melatih model *Deep Neural Network (DNN)* agar dapat mempelajari pola yang terdapat dalam dataset.
- b. Data Testing Sebanyak 20 data (20%) digunakan sebagai data testing. Data testing digunakan untuk menguji kemampuan model dalam melakukan prediksi terhadap data baru yang belum pernah digunakan dalam proses pelatihan. Hasil pengujian ini biasanya diukur menggunakan akurasi dengan rumus:

$$Accuracy = \frac{\text{jumlah prediksi benar}}{\text{jumlah seluruh data}} \times 100\% \quad (2)$$

3.4 Perancangan sistem

Tahap kelima adalah perancangan sistem. Pada bagian ini penulis menyusun alur kerja system dalam bentuk diagram alir (flowchart) agar mudah dipahami. Selain itu, dibagian ini juga membutuhkan perangkat keras (hardware) dan perangkat lunak (software) yang dilakukan mendukung keberhasilan implementasi program deteksi hipertensi tersebut. Berikut flowchart system perancangan:



Gambar 2 flowchart system perancangan

3.5 Pengujian dan Analisis Hasil

Tahap keenam adalah pengujian analisi hasil. Di sini, system diuji untuk QAQmelihat seberapa akurat algoritma *Deep Neural Network (DNN)* dalam mengenali gejala hipertensi. Hasil penguju ini menjadikan bahan evaluasi untuk menentukan apakah metode *DNN* efektif dan layak digunakan sebagai alat deteksi dini berdasarkan data Kesehatan yang ada.

4 Hasil dan Pembahasan

4.1 Deskripsi Data Penelitian

Dataset yang digunakan dalam penelitian ini merupakan data hasil skrining kesehatan masyarakat usia dewasa yang diperoleh dari kegiatan Posyandu Desa Tebas, Kecamatan

Gondangwetan, Kabupaten Pasuruan. Data tersebut digunakan sebagai dasar dalam membangun model deteksi dini hipertensi menggunakan metode Deep Neural Network (DNN).

Jumlah data yang digunakan dalam penelitian ini sebanyak 214 data responden. Setiap data terdiri dari beberapa atribut yang berkaitan dengan kondisi kesehatan individu, yaitu jenis kelamin, umur, berat badan, tinggi badan, lingkar perut, tekanan darah sistolik, tekanan darah diastolik, serta status hipertensi sebagai variabel target.

Tabel 1 Variabel Penelitian

<i>Variabel</i>	<i>Min</i>	<i>Max</i>	<i>Mean</i>
Umur	18	60	43,92
BB	20	175	102,70
TB	41	180	117,35
LP	60	111	87,83
Sistolik	100	200	147,73
Diastolik	30	120	85,40

4.2 Prosesing Data

Tahap preprocessing dilakukan untuk mempersiapkan data sebelum digunakan dalam proses pelatihan model Deep Neural Network. Tujuan dari tahap ini adalah menghasilkan data yang bersih, terstruktur, dan sesuai dengan kebutuhan algoritma pembelajaran mesin.

4.2.1 Pembersihan Data

Pada tahap awal dilakukan pemeriksaan terhadap data untuk mengetahui keberadaan data kosong (missing value), data duplikat, maupun kesalahan format data. Hasil pemeriksaan menunjukkan bahwa seluruh atribut memiliki jumlah data lengkap dan tidak ditemukan nilai kosong pada dataset. Dengan demikian tidak diperlukan proses imputasi ataupun penghapusan data.

Tabel 2 Hasil Pemeriksaan Missing Value

<i>Variable</i>	<i>Missing Value</i>
Gender	0
Umur	0
BB	0
TB	0
LP	0
Sistolik	0
Diastolic	0
Status	0

Berdasarkan hasil tersebut, seluruh data dapat digunakan pada tahap berikutnya tanpa perlu dilakukan penanganan khusus terhadap data yang hilang.

4.2.2 Seleksi Atribut

Dataset awal memiliki beberapa atribut tambahan yaitu nomor urut (No) dan nama responden (Nama). Kedua atribut tersebut tidak memiliki pengaruh terhadap proses klasifikasi hipertensi sehingga dihapus dari dataset. Atribut yang digunakan pada penelitian ini adalah

(1)Gender (2)Umur (3)Berat Badan (4)Tinggi Badan (5)Lingkar Perut (6)Tekanan Darah Sistolik dan (7)Darah Diastolik. Sedangkan atribut target yang digunakan adalah Status Hipertensi.

4.3 Transformasi Data Kategorikal

Algoritma Deep Neural Network hanya dapat memproses data dalam bentuk numerik. Oleh karena itu atribut kategorikal dilakukan proses transformasi menggunakan Label Encoding. Gender laki laki nilai 0, Perempuan nilai 1, sedangkan Label encoding status Hipertensi nilai 0 dan normal nilai 1. Melalui proses encoding tersebut seluruh atribut telah berubah menjadi bentuk numerik sehingga dapat digunakan pada tahap pelatihan model.

4.4 Standardisasi Data

Standardisasi data menggunakan metode StandardScaler. Standardisasi dilakukan untuk menyamakan skala seluruh atribut sehingga proses pembelajaran model menjadi lebih optimal. Metode StandardScaler mengubah data berdasarkan nilai rata-rata dan standar deviasi masing-masing atribut menggunakan persamaan rumus StandardScaler :

$$z = \frac{x - \mu}{\sigma} \quad (3)$$

Keterangan:

- z = nilai hasil standardisasi
- x = nilai data asli
- μ = nilai rata-rata
- σ = standar deviasi

Dengan standardisasi, seluruh atribut memiliki distribusi yang lebih seragam sehingga dapat meningkatkan stabilitas proses pelatihan model Deep Neural Network.

4.5 Pembagian Data Training dan Testing

Setelah proses preprocessing selesai dilakukan, dataset dibagi menjadi dua bagian yaitu data training dan data testing menggunakan metode train_test_split. Pembagian data dilakukan dengan rasio 80% untuk data training dan 20% untuk data testing. Teknik ini bertujuan agar model dapat mempelajari pola dari sebagian besar data dan kemudian diuji menggunakan data yang belum pernah dilihat sebelumnya.

4.6 Perancangan Model Deep Neural Network (DNN)

Setelah proses preprocessing dan pembagian dataset selesai dilakukan, tahap selanjutnya adalah merancang arsitektur model Deep Neural Network (DNN). Model ini digunakan untuk melakukan klasifikasi status hipertensi berdasarkan data skrining kesehatan yang telah dipersiapkan sebelumnya berikut perancangan model DNN:

4.6.1 Arsitektur Model

Model yang digunakan terdiri dari satu input layer, tiga hidden layer, dan satu output layer. Jumlah neuron pada setiap layer ditentukan berdasarkan proses eksperimen untuk memperoleh performa klasifikasi yang baik. Berdasarkan Tabel 3, model menerima tujuh atribut masukan yang terdiri dari gender, umur, berat badan, tinggi badan, lingkar perut, tekanan darah sistolik, dan tekanan darah diastolik. Fungsi aktivasi ReLU (Rectified Linear Unit) digunakan pada hidden layer karena mampu mengatasi permasalahan vanishing gradient dan

mempercepat proses pelatihan model. Sedangkan fungsi aktivasi Sigmoid digunakan pada output layer karena penelitian ini merupakan klasifikasi biner yang menghasilkan dua kelas yaitu hipertensi dan normal. Selain itu digunakan lapisan Dropout sebesar 0,2 untuk mengurangi risiko overfitting selama proses pelatihan model.

Tabel 3 Arsitektur Deep Neural Network

<i>Layer</i>	<i>Jumlah Neuron</i>	<i>Fungsi Aktivitas</i>
Input Layer	7	-
Hidden Layer 1	64	ReLU
Dropout	-	0,2
Hidden Layer 2	32	ReLU
Dropout	-	0,2
Hidden Layer 3	16	ReLU
Output Layer	1	Sigmoid

4.6.2 Parameter Model

Model Deep Neural Network dikompilasi menggunakan beberapa parameter pelatihan yang ditunjukkan pada Tabel 4

Tabel 4 Parameter Pelatihan Model

<i>Parameter</i>	<i>Nilai</i>
Optimizer	Adam
Loss Function	Binary Crossentropy
Epoch Maksimum	100
Batch Size	16
Validation Split	20%
Early Stopping	Ya

Optimizer Adam dipilih karena memiliki kemampuan konvergensi yang cepat dan stabil pada berbagai permasalahan klasifikasi. Fungsi Binary Crossentropy digunakan karena target penelitian terdiri dari dua kelas. Untuk mencegah overfitting digunakan teknik Early Stopping dengan parameter patience sebesar 10 epoch. Teknik ini akan menghentikan proses pelatihan apabila nilai validation loss tidak mengalami perbaikan dalam beberapa epoch berturut-turut.

4.6.3 Struktur Model

Hasil implementasi menunjukkan bahwa model memiliki total parameter sebanyak 3.137 parameter yang seluruhnya bersifat trainable parameter.

Tabel 5 Struktur Model DNN

<i>Layer</i>	<i>Output</i>	<i>Parameter</i>
Dense	(None, 64)	512
Dropout	(None, 64)	0
Dense	(None, 32)	2.080
Dropout	(None, 32)	0
Dense	(None, 16)	528

Dense	(None, 1)	17
Total	-	3.137

Jumlah parameter yang relatif kecil menunjukkan bahwa model tidak terlalu kompleks sehingga dapat dilatih dengan cepat namun tetap mampu mempelajari pola yang terdapat pada dataset. Berikut output hasil gambar dari Model.Summary ()

```
Total params: 3,137 (12.25 KB)
Trainable params: 3,137 (12.25 KB)
Non-trainable params: 0 (0.00 B)
```


Gambar 3 Model.Summary()

Hasil model.summary() menunjukkan bahwa model Deep Neural Network (DNN) yang dibangun memiliki total 3.137 parameter dengan ukuran memori sekitar 12,25 KB. Seluruh parameter tersebut termasuk ke dalam trainable parameters, artinya semua bobot dan bias pada setiap layer akan diperbarui selama proses pelatihan untuk meningkatkan kemampuan model dalam melakukan klasifikasi hipertensi.

4.7 Hasil Pelatihan Model

Tahap pelatihan model dilakukan menggunakan 171 data training yang telah melalui proses standardisasi. Pelatihan dilakukan dengan jumlah epoch maksimum sebanyak 100 epoch. Namun, karena menggunakan teknik Early Stopping, proses pelatihan berhenti secara otomatis pada epoch ke-29 ketika model tidak lagi menunjukkan peningkatan performa yang signifikan pada data validasi.

4.7.1 Hasil Akurasi Pelatihan




Gambar 4 Grafik Akurasi Model

Berdasarkan Gambar 4, nilai training accuracy meningkat dari sekitar 56% pada awal pelatihan menjadi hampir 98% pada akhir pelatihan. Sementara itu, validation accuracy mencapai

nilai tertinggi sekitar 97% dan stabil pada kisaran 89%–91% hingga akhir pelatihan. Hasil ini menunjukkan bahwa model mampu mempelajari pola data dengan baik dan memiliki kemampuan generalisasi yang cukup baik terhadap data yang tidak digunakan selama pelatihan.

4.7.2 Hasil Loss Pelatihan

Berikut output dari gambar dari Grafik Loss



Gambar 5 Output Hasil Grafik Loss

Berdasarkan Gambar 5, nilai training loss mengalami penurunan dari sekitar 0,68 menjadi 0,06 pada akhir pelatihan. Nilai validation loss juga menurun dari sekitar 0,58 menjadi 0,18. Penurunan nilai loss menunjukkan bahwa kesalahan prediksi model semakin kecil dan model mampu melakukan proses pembelajaran dengan baik tanpa mengalami overfitting yang signifikan.

4.7.3 Analisis Hasil Pelatihan

Berdasarkan grafik akurasi dan loss, model Deep Neural Network mampu mempelajari pola hubungan antara faktor kesehatan dan status hipertensi dengan baik. Beberapa indikator yang mendukung pernyataan tersebut antara lain:

1. Training accuracy mencapai lebih dari 95%.
2. Validation accuracy mencapai lebih dari 90%.
3. Training loss dan validation loss menunjukkan tren menurun.
4. Tidak terdapat perbedaan yang terlalu besar antara akurasi training dan validasi.

Dengan demikian model yang dibangun telah memenuhi kriteria untuk dilanjutkan pada tahap pengujian menggunakan data testing.

4.8 Hasil Pengujian Model

Setelah proses pelatihan selesai dilakukan, model diuji menggunakan 43 data testing yang tidak pernah digunakan selama proses pelatihan. Tujuan pengujian adalah untuk mengetahui kemampuan model dalam mengklasifikasikan status hipertensi pada data baru.


4.8.1 Confusion Matrix

Hasil pengujian menghasilkan confusion matrix sebagaimana ditunjukkan pada Tabel 6

Tabel 6 Confusion Matrix		
<i>Aktual</i>	<i>Prediksi Hipertensi</i>	<i>Prediksi Normal</i>
Hipertensi	31	3
Normal	2	7

Berdasarkan Tabel 4.6 dapat diketahui bahwa Sebanyak 31 data hipertensi berhasil diklasifikasikan dengan benar sebagai hipertensi, Sebanyak 3 data hipertensi salah diklasifikasikan sebagai normal, Sebanyak 7 data normal berhasil diklasifikasikan dengan benar sebagai normal, Sebanyak 2 data normal salah diklasifikasikan sebagai hipertensi.

Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali pola hipertensi pada data testing. Berikut output gambar dari hasil Confusion Matrix



Gambar 6 Output Hasil Confusion Matrix

Berdasarkan Gambar 6, hasil confusion matrix menunjukkan bahwa model berhasil mengklasifikasikan 31 data Hipertensi dan 7 data Normal dengan benar. Namun, terdapat 3 data Hipertensi yang diprediksi sebagai Normal serta 2 data Normal yang diprediksi sebagai Hipertensi. Hasil ini menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan tepat oleh model, sehingga model Deep Neural Network memiliki kinerja yang baik dalam mendeteksi status hipertensi.

4.8.2 Classification Report

Evaluasi performa model dilakukan menggunakan metrik precision, recall, dan F1-score.

Tabel 7 Hasil Classification Report			
<i>Kelas</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Hipertensi	0,94	0,91	0,93
Normal	0,70	0,78	0,74

Berdasarkan hasil tersebut, kelas hipertensi memiliki nilai precision sebesar 94% yang menunjukkan bahwa sebagian besar prediksi hipertensi yang dihasilkan model benar sesuai

kondisi aktual. Nilai recall sebesar 91% menunjukkan bahwa model mampu mendeteksi sebagian besar kasus hipertensi yang terdapat pada data testing. Sedangkan nilai F1-score sebesar 93% menunjukkan keseimbangan yang baik antara precision dan recall pada kelas hipertensi. Pada kelas normal diperoleh nilai F1-score sebesar 74%. Nilai ini lebih rendah dibandingkan kelas hipertensi karena jumlah data normal pada dataset lebih sedikit sehingga model memiliki informasi pembelajaran yang lebih terbatas terhadap kelas tersebut. Berikut output classification report

```

--- CLASSIFICATION REPORT ---
              precision    recall  f1-score   support

   Hipertensi         0.94        0.91        0.93         34
     Normal         0.70        0.78        0.74          9

 accuracy                   0.88         43
 macro avg         0.82        0.84        0.83         43
 weighted avg      0.89        0.88        0.89         43

Akurasi Akhir Model pada Data Testing: 88.37%

```

Gambar 7 Output Classification Report

Berdasarkan Gambar 4.6.2, model Deep Neural Network memperoleh akurasi sebesar 88,37% pada data testing. Pada kelas Hipertensi, model menghasilkan nilai precision 94%, recall 91%, dan f1-score 93%, yang menunjukkan kemampuan klasifikasi yang sangat baik. Sementara itu, pada kelas Normal, model memperoleh precision 70%, recall 78%, dan f1-score 74%. Secara keseluruhan, hasil classification report menunjukkan bahwa model mampu mengklasifikasikan status hipertensi dengan baik dan memiliki performa yang cukup tinggi pada data pengujian.

4.8.3 Akurasi Model

Akurasi digunakan untuk mengukur persentase prediksi yang benar dibandingkan dengan seluruh data pengujian.

Rumus akurasi adalah:

$$Accuracy = \frac{\text{jumlah prediksi benar}}{\text{jumlah seluruh data}} \times 100\% \quad (4)$$

- Berdasarkan hasil pengujian diperoleh:
- Jumlah prediksi benar = 38 data
- Jumlah data testing = 43 data
- Sehingga:
- Akurasi = $(38 / 43) \times 100\%$
- Akurasi = 88,37%
- Hasil Akurasi Model 88,37%

Nilai akurasi sebesar 88,37% menunjukkan bahwa model Deep Neural Network mampu melakukan deteksi dini hipertensi dengan tingkat ketepatan yang cukup tinggi pada data skrining kesehatan yang digunakan dalam penelitian ini.

4.9 Perbandingan Hasil Dengan Penelitian Terdahulu

Tabel 8 Perbandingan Hasil Dengan Penelitian Terdahulu

No	Peneliti	Tahun	Metode	Hasil Akurasi
1	Mayanda all	2020	Naive bayes	85%
2	Nafid all	2025	Naive bayes	87%
3	Donghwan all	2023	Deep Learning (Temporal Fusion Transformer)	nilai AUROC 0,953
4	Sofiah	2026	Deep Neural Network	88,37%

Berdasarkan tabel 8 penelitian Mayanda Mega Santoni all. (2020) menggunakan metode Naive Bayes dan memperoleh akurasi sebesar 82,5%. Selanjutnya, penelitian Nafid all. (2025) yang juga menggunakan metode Naive Bayes memperoleh akurasi sebesar 87%. Penelitian Donghwan Yun all. (2023) menggunakan metode Deep Learning Temporal Fusion Transformer dan menghasilkan nilai AUROC sebesar 0,953. Pada penelitian ini, metode Deep Neural Network (DNN) memperoleh akurasi sebesar 88,37%. Hasil tersebut menunjukkan bahwa metode DNN mampu memberikan performa yang baik dalam mengklasifikasikan status hipertensi berdasarkan data kesehatan yang digunakan.

4.10 Ringkasan Hasil

Penelitian ini berhasil membangun model deteksi dini hipertensi pada usia dewasa menggunakan metode Deep Neural Network (DNN) berdasarkan data skrining kesehatan masyarakat. Dataset yang digunakan sebanyak 214 data responden, yang dibagi menjadi 171 data training dan 43 data testing. Sebelum pelatihan, data melalui tahap preprocessing berupa pembersihan data, transformasi data kategorikal, dan standardisasi menggunakan *StandardScaler*. Model DNN yang dibangun menggunakan tiga hidden layer dengan fungsi aktivasi ReLU dan output layer dengan fungsi aktivasi Sigmoid. Hasil pengujian menunjukkan akurasi sebesar 88,37%, precision 94%, recall 91%, dan F1-score 93% pada kelas hipertensi. Hasil tersebut menunjukkan bahwa metode DNN mampu melakukan deteksi dini hipertensi dengan baik dan berpotensi digunakan sebagai alat bantu skrining kesehatan.

5 Simpulan dan Saran

5.1 Simpulan

Penelitian ini berhasil membangun dan menguji model deteksi dini penyakit hipertensi pada usia dewasa dengan mengimplementasikan metode *Deep Neural Network* (DNN) berbasis data skrining kesehatan posyandu. Melalui pemanfaatan 214 data responden yang diolah dengan *StandardScaler*, model DNN dengan arsitektur 3 hidden layer (64, 32, 16 neuron), optimizer Adam, regularisasi Dropout 0.2, serta Early Stopping mampu memberikan performa yang sangat optimal. Pengujian pada data testing menghasilkan nilai akurasi sistem yang tinggi sebesar 88,37%. Untuk kelas deteksi hipertensi, model mencatatkan nilai *precision* sebesar 94%, *recall* sebesar 91%, dan *F1-score* sebesar 93%. Dengan demikian, metode DNN terbukti efektif, aplikatif, dan berpotensi besar untuk diintegrasikan sebagai alat bantu digital bagi kader kesehatan dalam skrining dini hipertensi

5.2 Saran

Beberapa langkah pengembangan yang dapat dilakukan untuk menyempurnakan penelitian ini ke depan antara lain: menambah volume dan variasi persebaran dataset kesehatan masyarakat dari berbagai wilayah posyandu, menguji optimasi hiperparameter model (seperti variasi jumlah epoch, learning rate, atau jenis optimizer lainnya) guna mendongkrak akurasi di

atas 90%, serta mengintegrasikan model DNN ini ke dalam antarmuka aplikasi berbasis mobile atau website agar dapat dioperasikan secara langsung oleh tenaga medis di lapangan.

Referensi

- World Health Organization. (2023). Global report on hypertension: The race against a silent killer. World Health Organization.
<https://www.who.int/publications/i/item/9789240081062>
- Santoni, M. M., Chamidah, N., & Matondang, N. (2020). Prediksi hipertensi menggunakan decision tree, naive bayes dan artificial neural network pada software KNIME. *Technologia: Jurnal Ilmiah*, 11(4), 234–240.
- Sutriawan, Fanani, A. Z., Alzami, F., & Basuki, R. S. (2023). Deep Learning Jaringan Saraf Tiruan Untuk Pemecahan Masalah Deteksi Penyakit Daun Apel. *Jurnal TIKomSiN*, 11(1). <https://doi.org/10.30646/tikomsin.v11i1.729>
- Nisa, N. K., Sani, D. A., & Udin, M. (2025). Prediksi dini resiko penyakit diabetes menggunakan jaringan syaraf tiruan backpropagation. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(5), 9096-9102
- Yun, D., Yang, H. L., Kim, S. G., Lee, J., Kim, Y., & Kim, H. C. (2023). Real-time dual prediction of intradialytic hypotension and hypertension using an explainable deep learning model. *Scientific Reports*, 13, 18254. <https://doi.org/10.1038/s41598-023-45282-1>
- Kurniawan, R., Utomo, B., Siregar, K. N., Ramli, K., Besral, Suhatril, R. J., & Pratiwi, O. A. (2023). Hypertension prediction using machine learning algorithm among Indonesian adults. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 12(2), 776–784. <https://doi.org/10.11591/ijai.v12.i2.pp776-784>
- Bisong, E., Jibril, N., Premnath, P., Buligwa, E., Oboh, G., & Chukwuma, A. (2024). Predicting high blood pressure using machine learning models in low- and middle-income countries. *BMC Medical Informatics and Decision Making*, 24(234). <https://doi.org/10.1186/s12911-024-02634-9>
- Omankwu, O. C. B., Okoronkwo, M. C., & Kanu, C. (2024). Cardiovascular (Heart) Diseases Prediction using Deep Learning Neural Network Model. *NIPES Journal of Science and Technology Research*, 6(1), 28–40. <https://doi.org/10.5281/zenodo.10802375>