



### Prediksi Risiko Tekanan Darah Tinggi dengan Menerapkan Artificial Neural Network

*Prediction of Hypertension Risk Using Artificial Neural Network*

Ilham Kurniawan<sup>1</sup>, Abdussomad<sup>2</sup>, Agung Wibowo<sup>3</sup>

<sup>1,2,3</sup>Program Studi Sistem Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

<sup>1</sup>ilham.imk@bsi.ac.id, <sup>2</sup>abdussomad.bdu@bsi.ac.id, <sup>3</sup>agung.awo@bsi.ac.id

#### Abstract

Hypertension is one of the chronic diseases that constitutes a major risk factor for cardiovascular disorders and requires early detection to prevent serious complications. Previous studies have implemented Artificial Neural Network (ANN) models using real clinical datasets and achieved an accuracy of approximately 85%; however, their application remains limited by the type and availability of the datasets. In addition, the use of synthetic but realistic datasets as an alternative for model evaluation is still relatively underexplored. Therefore, this study aims to develop an ANN model to perform binary classification of individuals with and without hypertension using a synthetic but realistic dataset. The training process was conducted by monitoring the accuracy and validation loss, while the model performance was evaluated using accuracy, precision, recall, and F1-score metrics. The results show that the ANN model achieved an accuracy of 87.8%, with a balanced capability in identifying both hypertensive and non-hypertensive individuals. The confusion matrix indicates a high number of correct predictions in both classes, confirming the robustness of the model in supporting binary classification on health-related data. These findings demonstrate that ANN maintains excellent performance when applied to a realistic synthetic dataset and has strong potential as an effective approach to support medical decision support systems, particularly for early detection of hypertension and for reducing the risk of long-term complications through more timely interventions.

*Keywords:* Artificial Neural Network, Binary Classification Confusion Matrix, Hypertension

#### Abstrak

Tekanan darah tinggi merupakan salah satu penyakit kronis yang menjadi faktor risiko utama penyakit kardiovaskular dan membutuhkan deteksi dini untuk mencegah komplikasi serius. Penelitian sebelumnya telah menerapkan model *Artificial Neural Network* (ANN) berbasis data klinis nyata dengan tingkat akurasi sekitar 85%, namun masih terbatas pada jenis dan ketersediaan dataset tertentu. Selain itu, pemanfaatan dataset sintetis yang bersifat realistik sebagai alternatif pengujian model masih relatif jarang dilakukan. Oleh karena itu, penelitian ini bertujuan mengembangkan model ANN dalam melakukan klasifikasi biner terhadap individu dengan dan tanpa tekanan darah tinggi menggunakan dataset synthetic but realistic. Data latih digunakan untuk melatih model dengan memantau metrik *accuracy* dan *validation loss*, sementara evaluasi kinerja dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa model ANN mencapai akurasi sebesar 87,8%, dengan kemampuan yang seimbang dalam mengidentifikasi pasien tekanan darah tinggi maupun non-tekanan darah tinggi. *Confusion matrix* memperlihatkan jumlah prediksi benar yang cukup tinggi pada kedua kelas, sehingga menegaskan kemampuan model dalam mendukung klasifikasi biner pada data kesehatan. Temuan ini menunjukkan bahwa ANN tetap memberikan kinerja yang sangat baik meskipun diterapkan pada dataset synthetic but realistic, serta berpotensi menjadi pendekatan yang efektif untuk mendukung sistem pendukung keputusan medis, khususnya dalam mendekati dini tekanan darah tinggi dan mengurangi risiko komplikasi jangka panjang melalui intervensi yang lebih tepat waktu.

Kata kunci: Artificial Neural Network, Confusion Matrix, Tekanan darah tinggi, Klasifikasi Biner

#### 1. Pendahuluan

Tekanan darah tinggi merupakan tantangan kesehatan global yang signifikan karena prevalensinya yang tinggi serta keterkaitannya dengan penyakit kardiovaskular dan penyakit ginjal kronis [1]. Tekanan darah tinggi merupakan kondisi medis yang umum, memengaruhi sekitar 1 dari 4 orang [2], dan menjadi faktor risiko

signifikan terhadap serangan jantung, stroke, dan penyakit ginjal [3]. Secara global, tekanan darah tinggi dikaitkan dengan 13% angka kematian [4] dan menjadi beban kesehatan yang signifikan bagi seluruh lapisan populasi. Oleh karena itu, strategi pencegahan serta pengendalian tekanan darah tinggi perlu menjadi prioritas utama [5]. Pencegahan dapat dilakukan melalui pendekatan yang menyasar populasi umum

maupun individu dengan risiko lebih tinggi [6]. Perkembangan teknologi informasi dan ketersediaan data biomedis dalam jumlah besar telah membuka peluang baru dalam pengembangan sistem prediksi berbasis kecerdasan buatan di bidang kesehatan. Data ini dimanfaatkan untuk menilai prevalensi, faktor risiko, diagnosis, tingkat keparahan penyakit, serta memperkirakan risiko komplikasi lanjutan sehingga memungkinkan dilakukan intervensi secara lebih dini dan tepat [7][8][9].

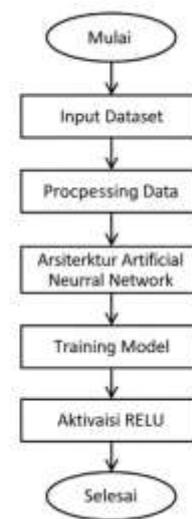
Sejumlah penelitian sebelumnya telah menerapkan metode *machine learning*, termasuk *Artificial Neural Network* (ANN), untuk memprediksi risiko tekanan darah tinggi dengan tingkat akurasi yang cukup baik. Salah satu penelitian berbasis data klinis nyata melaporkan bahwa ANN mampu mencapai akurasi sekitar 85% dalam klasifikasi jenis penyakit hipertensi [10]. Namun demikian, sebagian besar penelitian masih bergantung pada dataset nyata yang ketersediaannya terbatas, sulit diakses, serta memiliki kendala etika dan privasi pasien. Selain itu, pemanfaatan dataset *synthetic but realistic* sebagai alternatif dalam pengujian model prediksi tekanan darah tinggi masih relatif jarang diteliti. Kondisi ini menunjukkan adanya *research gap* terkait validasi kinerja ANN pada dataset sintetis yang tetap merepresentasikan karakteristik data kesehatan nyata.

ANN sendiri merupakan metode pembelajaran mesin yang meniru cara kerja sistem saraf manusia dalam memproses informasi [11][12]. ANN memiliki kemampuan yang sangat baik dalam mengenali pola *nonlinier* yang kompleks, termasuk hubungan antara usia, tekanan darah, indeks massa tubuh, serta variabel klinis lainnya terhadap kejadian tekanan darah tinggi [13]. Kemampuan ini menjadikan ANN sebagai salah satu metode yang potensial untuk diterapkan dalam sistem prediksi penyakit berbasis data kesehatan. Berdasarkan gap tersebut, penelitian ini menjadi urgen untuk dilakukan guna mengkaji sejauh mana kinerja ANN tetap optimal ketika diterapkan pada dataset *synthetic but realistic* sebagai alternatif pengganti data medis nyata. Oleh karena itu, penelitian ini bertujuan untuk membangun model ANN dalam melakukan klasifikasi biner individu dengan dan tanpa tekanan darah tinggi menggunakan dataset *synthetic but realistic*. Hasil penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan medis berbasis kecerdasan buatan yang lebih fleksibel, aman dari sisi privasi, serta tetap memiliki tingkat akurasi yang tinggi dalam deteksi dini tekanan darah tinggi.

## 2. Metode Penelitian

Tahapan penelitian ini dirancang secara sistematis untuk membangun model ANN dalam klasifikasi

tekanan darah tinggi. Alur proses penelitian dimulai dari tahap *input* dataset, yaitu pengambilan data dalam format CSV yang digunakan sebagai bahan utama penelitian. Selanjutnya dilakukan tahap *processing* data, yang mencakup pembersihan data dari nilai yang hilang, normalisasi data, serta proses *encoding* pada variabel kategorikal agar dapat diproses oleh model. Setelah data siap digunakan, proses dilanjutkan ke tahap arsitektur ANN, yang terdiri dari lapisan *input*, satu atau lebih *hidden layer*, serta lapisan *output* sebagai penghasil nilai prediksi. Tahap berikutnya adalah *training model*, di mana data latih digunakan untuk melatih model melalui proses *forward propagation* dan *backpropagation* guna memperbarui bobot jaringan hingga diperoleh model dengan performa optimal. Proses penelitian diakhiri dengan tahap selesai, yaitu diperolehnya model ANN yang siap digunakan untuk melakukan klasifikasi tekanan darah tinggi.



Gambar 1. Flowchart Implementasi Penelitian

### 2.1. Input Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari *platform Kaggle*. Dataset ini merupakan dataset sintetik yang bersifat realistik (*synthetic but realistic*), yang dikembangkan untuk menyerupai karakteristik data klinis pasien dengan risiko tekanan darah tinggi. Penggunaan dataset sintetis dipilih sebagai alternatif yang aman dan etis karena tidak melibatkan data pasien secara langsung, sehingga tidak menimbulkan risiko pelanggaran privasi maupun aspek kerahasiaan informasi medis. Dataset disajikan dalam format *Comma-Separated Values* (CSV) sehingga mudah diolah menggunakan berbagai perangkat lunak analisis data dan pustaka pembelajaran mesin. Data ini terdiri atas sejumlah atribut yang merepresentasikan faktor demografis, gaya hidup, serta kondisi klinis individu yang berhubungan dengan risiko tekanan darah tinggi. Beberapa variabel utama yang terdapat dalam dataset meliputi usia, jenis kelamin, indeks massa tubuh (*Body*

*Mass Index/BMI*), kadar glukosa, tekanan darah sistolik dan diastolik, status merokok, aktivitas fisik, serta sejumlah variabel pendukung lainnya yang relevan dengan kondisi kesehatan kardiovaskular. Label kelas pada dataset ini bersifat biner, yaitu menunjukkan apakah seseorang termasuk dalam kategori mengalami tekanan darah tinggi (hipertensi) atau tidak mengalami tekanan darah tinggi (non-hipertensi). Dengan demikian, dataset ini sangat sesuai untuk digunakan dalam permasalahan klasifikasi biner menggunakan pendekatan ANN. Dalam penelitian ini, dataset tersebut digunakan sebagai sumber data utama (*input* dataset) untuk proses pemodelan. Sebelum digunakan pada tahap pembentukan arsitektur jaringan saraf tiruan, dataset terlebih dahulu melalui tahap processing data, yang mencakup pembersihan data dari nilai kosong (*missing value*), transformasi data, normalisasi, serta proses *encoding* pada variabel kategorikal agar dapat diproses secara numerik oleh model ANN. Tahapan ini bertujuan untuk meningkatkan kualitas data, mempercepat proses pelatihan model, serta meningkatkan stabilitas dan akurasi hasil klasifikasi.

## 2.2. Preprocessing Data

Pra-pemrosesan data, merupakan tahap fundamental yang dilakukan sebelum data digunakan dalam analisis atau pelatihan model. Tujuan utamanya adalah meningkatkan kualitas data, memperbaiki ketidakhomogenan, serta menangani masalah seperti *missing values*, *noise*, inkonsistensi, dan ketidakseimbangan data, demi mendukung keandalan dan akurasi model prediksi [14]. Dalam tahap pra-

pemrosesan data, dilakukan serangkaian prosedur untuk menyiapkan dataset agar dapat digunakan dalam pelatihan dan pengujian model. Data yang digunakan berupa dataset tekanan darah tinggi dalam bentuk file CSV, yang berisi sejumlah variabel klinis serta informasi riwayat kesehatan.

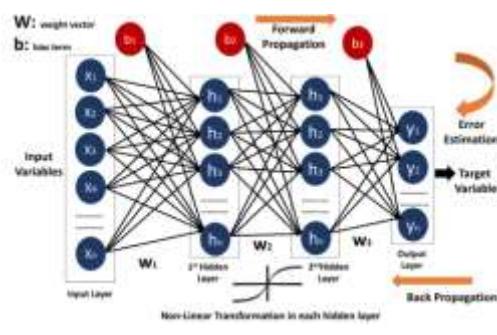
Proses awal dimulai dengan pembersihan data, yaitu menghapus entri yang memiliki nilai “?” serta baris dengan data kosong, sehingga hanya data yang valid dan konsisten yang digunakan pada tahap berikutnya. Setelah itu dilakukan seleksi fitur, di mana hanya variabel yang relevan dengan prediksi tekanan darah tinggi yang dipertahankan, antara lain *Age*, *Salt Intake*, *Stress Score*, *BP History*, *Sleep Duration*, *BMI*, *Medication*, *Family History*, *Exercise Level*, *Smoking Status*, serta label target *Has Hypertension*. Selanjutnya, untuk mengatasi keberadaan variabel kategorikal, dilakukan proses transformasi dengan *Label Encoding* agar setiap kategori dapat direpresentasikan dalam bentuk numerik. Transformasi ini bertujuan agar seluruh fitur dapat diproses oleh model ANN yang membutuhkan masukan dalam format angka. Dataset yang telah melalui proses ini kemudian dibagi menjadi data latih, data uji, dan data validasi, sehingga memungkinkan evaluasi performa model secara menyeluruh. Dengan demikian, pra-pemrosesan data dalam penelitian ini mencakup tahapan pembersihan, seleksi variabel penting, serta transformasi data kategorikal menjadi numerik, yang keseluruhannya dirancang untuk meningkatkan kualitas data dan akurasi prediksi tekanan darah tinggi.

Tabel 1. Dataset Hipertensi

Age	Salt_Intake	Stress_Score	BP_History	Sleep_Duration	BMI	Medic_ation	Family_History	Exercise_Level	Smoking_Status	Has_Hypertension
38	10.0	10	0	4.2	22.1	0	0	1	0	1
41	9.8	1	2	5.8	16.2	3	0	2	0	0
20	10.8	3	0	5.2	21.9	1	1	0	0	1
39	8.9	0	1	7.8	27.6	1	1	0	0	0
19	9.3	7	1	4.7	36.5	1	1	1	1	1

## 2.3. Arsitektur Artificial Neural Network

Model yang digunakan dalam penelitian ini adalah ANN dengan pendekatan *Multilayer Perceptron* (MLP) [15].



Gambar 2. Arsitektur ANN

ANN ini terdiri atas tiga komponen utama, yaitu *input layer*, *hidden layer*, dan *output layer*. Pada tahap *input layer*, terdapat 10 *neuron* yang merepresentasikan variabel prediktor yang telah melalui tahap prapemrosesan, yaitu *Age*, *Salt Intake*, *Stress Score*, *BP History*, *Sleep Duration*, *BMI*, *Medication*, *Family History*, *Exercise Level*, dan *Smoking Status*. Selanjutnya, arsitektur *hidden layer* dibangun menggunakan sejumlah neuron dengan fungsi aktivasi ReLU (*Rectified Linear Unit*). Fungsi ini dipilih karena mampu menangani masalah *vanishing gradient* dan mempercepat proses pelatihan [16]. Sementara itu, *output layer* terdiri atas satu neuron dengan fungsi aktivasi *sigmoid*, karena kasus yang dihadapi merupakan klasifikasi biner (memiliki tekanan darah

DOI: <https://doi.org/10.38204/tematik>

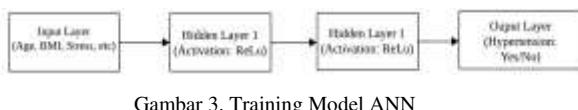
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

tinggi atau tidak) [17]. Model ANN dilatih menggunakan algoritma *backpropagation* dengan *optimizer* Adam, yang dikenal mampu melakukan penyesuaian bobot secara adaptif [18][19]. Proses pelatihan dilakukan sebanyak 50 *epoch* dengan ukuran *batch* tertentu, sehingga model dapat mempelajari pola data secara bertahap. Selain itu, *loss function* yang digunakan adalah *binary crossentropy*, yang sesuai untuk permasalahan klasifikasi biner.

#### 2.4. Training Model

Tahapan utama dalam proses pelatihan ANN, dimulai dari *forward propagation*, yaitu ketika data masukan yang telah melalui tahap prapemrosesan dimasukkan ke dalam jaringan. Pada tahap ini, kombinasi linear bobot dan bias dihitung, kemudian hasilnya diproses oleh fungsi aktivasi ReLU pada *hidden layer* untuk menghasilkan keluaran non-linear yang mampu merepresentasikan pola kompleks. Selanjutnya, lapisan output dengan fungsi aktivasi sigmoid mengubah nilai menjadi probabilitas biner, yang mencerminkan kemungkinan seseorang mengalami tekanan darah tinggi. Hasil prediksi ini kemudian dibandingkan dengan label aktual menggunakan fungsi *binary cross-entropy loss*, yang menghitung tingkat kesalahan model. Tahap berikutnya adalah *backpropagation*, yaitu propagasi balik error ke seluruh jaringan saraf. Proses ini digunakan untuk memperbarui bobot dan biasa dengan bantuan algoritma optimasi Adam, yang dipilih karena kemampuannya dalam mempercepat konvergensi serta menyesuaikan *learning rate* secara adaptif.

Selama pelatihan, pembaruan bobot dilakukan secara bertahap dengan menggunakan *mini-batch*, di mana dataset dibagi ke dalam subset kecil agar proses komputasi lebih efisien dan stabil. Iterasi ini berlangsung selama 50 *epoch*, sehingga memungkinkan model untuk belajar secara bertahap hingga mencapai akurasi optimal dalam mengklasifikasikan tekanan darah tinggi. Proses pelatihan ini bertujuan untuk meminimalkan nilai *loss function* sekaligus mengoptimalkan parameter jaringan, sehingga ANN mampu mengenali pola non-linear yang kompleks pada data klinis. Ilustrasi umum mengenai alur *training model* ANN dapat dilihat pada Gambar 2.



Gambar 3. Training Model ANN

#### 2.5. Rectified Linear Unit (ReLU)

Fungsi aktivasi merupakan komponen penting dalam jaringan saraf tiruan karena berperan dalam memperkenalkan sifat non-linear pada model, sehingga jaringan mampu mempelajari pola kompleks dari data. Salah satu fungsi aktivasi yang paling banyak digunakan saat ini adalah *Rectified Linear Unit* (ReLU).

Secara matematis, ReLU didefinisikan sebagai Persamaan 1.

$$f(x) = \max(0, x) \quad (1)$$

setiap *input* bernilai positif akan diteruskan secara linear, sedangkan *input* negatif akan dikonversi menjadi nol. Sifat sederhana ini menjadikan ReLU lebih efisien dibandingkan fungsi aktivasi klasik seperti *sigmoid* atau *tanh*, karena tidak menimbulkan permasalahan *vanishing gradient* yang sering menghambat proses pelatihan pada jaringan dalam (*deep network*) [20].

Keunggulan utama ReLU adalah kemampuannya mempercepat proses pelatihan dengan menghasilkan konvergensi lebih cepat, serta menjaga representasi sparsitas pada *neuron*, yang berarti hanya sebagian *neuron* yang aktif pada suatu waktu. Hal ini berdampak positif dalam meningkatkan generalisasi model terhadap data baru [21]. Dalam penelitian ini, penggunaan fungsi aktivasi ReLU pada *hidden layer* jaringan saraf tiruan bertujuan untuk meningkatkan kemampuan model dalam mengenali pola *non-linear* yang berkaitan dengan faktor risiko tekanan darah tinggi. Pemilihan ReLU dianggap tepat karena data klinis dan gaya hidup pasien tekanan darah tinggi cenderung memiliki hubungan kompleks yang tidak sepenuhnya dapat ditangkap oleh fungsi linear sederhana. Dengan demikian, implementasi ReLU mendukung pencapaian akurasi klasifikasi yang lebih baik dalam model prediksi tekanan darah tinggi yang dikembangkan.

#### 2.6. Evaluasi Model

Setelah proses pelatihan selesai, tahap selanjutnya adalah melakukan evaluasi model untuk mengukur performa jaringan saraf tiruan terhadap data yang tidak digunakan selama proses pelatihan. Evaluasi ini bertujuan untuk mengetahui sejauh mana model mampu melakukan generalisasi pada data baru. Dalam penelitian ini, evaluasi dilakukan dengan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Akurasi digunakan untuk menghitung proporsi prediksi yang benar dibandingkan dengan total prediksi, sedangkan *precision* dan *recall* digunakan untuk menilai performa model pada kelas positif. *F1-score* dipakai sebagai ukuran harmonisasi antara *precision* dan *recall* agar penilaian menjadi lebih seimbang. Selain itu, evaluasi juga dilakukan dengan menganalisis perbandingan nilai *accuracy* dan *loss* pada data pelatihan dan validasi untuk mengetahui kestabilan serta konsistensi model. Perhitungan metrik tersebut dapat dirumuskan sebagaimana pada Persamaan (2), (3), (4), dan (5), yang menggambarkan formula *accuracy*, *precision*, *recall*, dan *F1-score*.

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

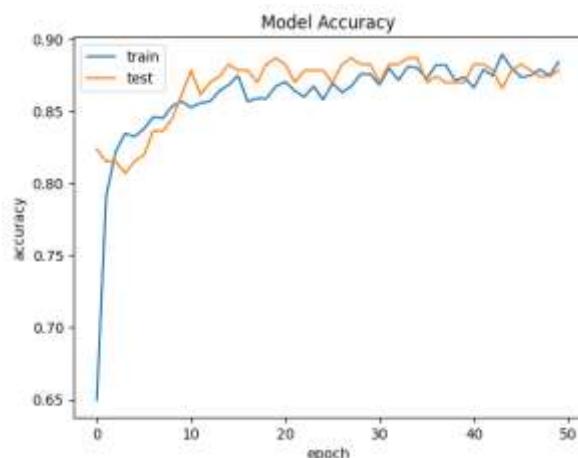
$$\text{Precision} : \frac{TP}{TP+FP} \times 100\% \quad (3)$$

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

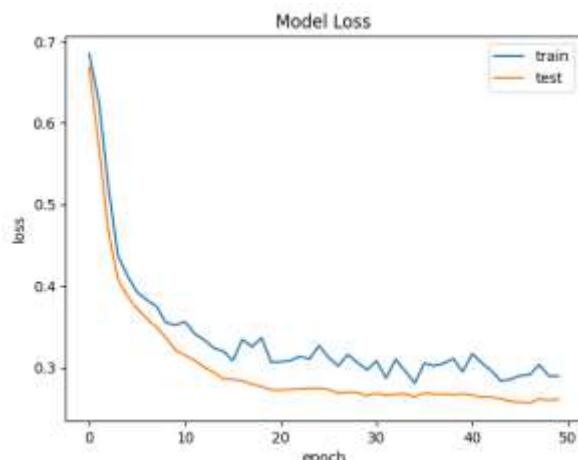
$$F1 - Score : 2x \frac{Precision \times Recall}{Precision + Recall} \times 100\% \quad (5)$$

### 3. Hasil dan Pembahasan

Hasil pelatihan model ANN ditunjukkan melalui grafik akurasi dan *loss* selama proses training sebagaimana tersaji pada Gambar 4 dan Gambar 5. Grafik tersebut memperlihatkan bahwa nilai akurasi meningkat secara bertahap seiring bertambahnya *epoch*, sementara nilai *loss* mengalami penurunan yang stabil. Pola ini menunjukkan bahwa model mampu mempelajari pola data dengan baik serta memiliki proses pembelajaran yang konvergen. Selain itu, tidak terlihat adanya perbedaan yang tajam antara performa data latih dan data validasi, yang mengindikasikan bahwa model tidak mengalami *overfitting* secara signifikan.



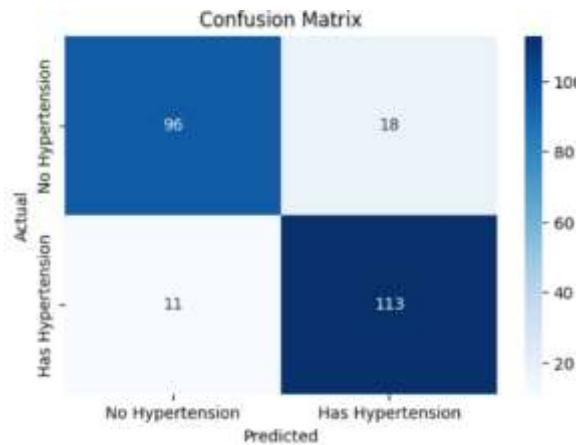
Gambar 4. Model Accuracy



Gambar 5. Model Loss

Berdasarkan hasil evaluasi menggunakan *confusion matrix* pada Gambar 6, diperoleh jumlah prediksi benar sebanyak 96 data pada kelas *No Hypertension* dan 113 data pada kelas *Has Hypertension*, dengan kesalahan prediksi sebanyak 18 data *false positive* dan 11 data

*false negative*. Dari hasil tersebut diperoleh nilai akurasi keseluruhan sebesar 87,8%, yang menunjukkan bahwa model ANN memiliki kemampuan klasifikasi yang baik dalam membedakan individu yang mengalami tekanan darah tinggi dan yang tidak mengalaminya.



Gambar 6. Confusion Matrix

Tingginya nilai akurasi yang diperoleh dalam penelitian ini dipengaruhi oleh beberapa faktor penting. Pertama, kualitas dataset *synthetic but realistic* yang digunakan memiliki karakteristik distribusi data yang menyerupai data klinis nyata. Variabel-variabel seperti usia, BMI, riwayat tekanan darah, stres, serta pola aktivitas fisik memiliki keterkaitan yang kuat dengan status hipertensi, sehingga memudahkan model dalam mempelajari pola hubungan antar variabel tersebut. Kedua, proses *preprocessing* yang optimal, terutama pada tahap pembersihan data, seleksi fitur, normalisasi, serta *encoding* variabel kategorikal, turut berperan besar dalam meningkatkan stabilitas pembelajaran jaringan saraf.

Faktor ketiga yang berkontribusi terhadap tingginya akurasi adalah pemilihan arsitektur ANN yang tepat, yaitu penggunaan *Multilayer Perceptron* (MLP) dengan fungsi aktivasi *ReLU* pada *hidden layer* serta *sigmoid* pada *output layer*. *ReLU* membantu jaringan dalam mengenali pola non-linear secara lebih efektif dan menghindari permasalahan *vanishing gradient*, sehingga proses pembaruan bobot menjadi lebih optimal. Sementara itu, penggunaan *optimizer* Adam juga mempercepat konvergensi model karena mampu menyesuaikan *learning rate* secara adaptif.

Selain itu, keseimbangan antara nilai *precision* dan *recall* yang diperoleh menunjukkan bahwa model tidak hanya andal dalam memprediksi individu yang benar-benar mengalami tekanan darah tinggi, tetapi juga cukup baik dalam menghindari kesalahan deteksi pada individu yang sebenarnya tidak mengalami hipertensi. Hal ini sangat penting dalam konteks medis, karena kesalahan klasifikasi dapat berdampak pada

keterlambatan penanganan maupun kesalahan intervensi.

Jika dibandingkan dengan penelitian sebelumnya yang menggunakan dataset klinis nyata dengan tingkat akurasi sekitar 85%, hasil penelitian ini menunjukkan performa yang sedikit lebih tinggi meskipun menggunakan dataset *synthetic but realistic*. Hal ini mengindikasikan bahwa dataset sintetis yang dirancang dengan baik tetap mampu merepresentasikan karakteristik data kesehatan secara akurat, serta layak digunakan sebagai alternatif pengujian model prediksi berbasis kecerdasan buatan tanpa menimbulkan risiko pelanggaran privasi pasien.

Dengan demikian, capaian akurasi sebesar 87,8% dalam penelitian ini tidak hanya mencerminkan keberhasilan model ANN dalam melakukan klasifikasi, tetapi juga menunjukkan bahwa kombinasi antara kualitas data, teknik *preprocessing*, pemilihan arsitektur jaringan, serta strategi pelatihan yang tepat merupakan faktor utama yang memengaruhi kinerja model. Hasil ini memperkuat bukti bahwa ANN sangat potensial untuk diterapkan dalam sistem pendukung keputusan medis, khususnya untuk deteksi dini tekanan darah tinggi.

#### 4. Kesimpulan

Penelitian ini berhasil mengembangkan model ANN untuk melakukan prediksi tekanan darah tinggi menggunakan pendekatan klasifikasi biner berbasis dataset *synthetic but realistic*. Hasil pelatihan dan pengujian menunjukkan bahwa model mampu mencapai tingkat akurasi sebesar 87,8%, dengan performa yang seimbang dalam mengklasifikasikan kelas tekanan darah tinggi maupun non-tekanan darah tinggi. Evaluasi menggunakan *confusion matrix* juga menunjukkan tingkat kesalahan prediksi yang relatif rendah, sehingga mencerminkan kemampuan model dalam mendeteksi kasus hipertensi secara cukup andal. Tingginya tingkat akurasi yang diperoleh menunjukkan bahwa dataset sintetis yang dirancang secara realistis mampu merepresentasikan karakteristik data klinis dengan baik, sehingga layak digunakan sebagai media pengujian awal bagi pengembangan model prediksi berbasis kecerdasan buatan. Kombinasi antara kualitas data, tahapan *processing* data yang optimal, serta pemilihan arsitektur ANN dan fungsi aktivasi ReLU berperan penting dalam menghasilkan kinerja model yang optimal.

Secara praktis, model ANN yang dikembangkan berpotensi diimplementasikan sebagai sistem pendukung keputusan medis, baik pada layanan kesehatan primer maupun dalam integrasi dengan sistem rekam medis elektronik, khususnya untuk mendukung proses skrining awal tekanan darah tinggi secara cepat dan efisien. Meskipun hasil yang diperoleh

menunjukkan kinerja yang baik, pengujian lanjutan menggunakan dataset klinis nyata tetap diperlukan sebagai tahap validasi eksternal untuk mengukur tingkat generalisasi model pada kondisi dunia nyata. Selain itu, pengembangan selanjutnya dapat dilakukan dengan menambahkan variabel gaya hidup, data longitudinal, serta data *real-time* dari perangkat kesehatan guna meningkatkan akurasi dan keandalan sistem secara lebih komprehensif.

#### Daftar Rujukan

- [1] M. Fang *et al.*, “A hybrid machine learning approach for hypertension risk prediction,” *Neural Comput. Appl.*, vol. 35, no. 20, pp. 14487–14497, 2023, doi: 10.1007/s00521-021-06060-0.
- [2] K. T. Mills *et al.*, “Global disparities of hypertension prevalence and control,” *Circulation*, vol. 134, no. 6, pp. 441–450, 2016, doi: 10.1161/CIRCULATIONAHA.115.018912.
- [3] R. A. Prasodo and F. Farapti, “Literature Review: Strategi Penurunan Asupan Natrium Melalui Pengurangan Garam untuk Mencegah Hipertensi,” *Media Gizi Kesmas*, pp. 521–529, 2024, doi: doi.org/10.20473/mgk.v13i1.2024.521-529.
- [4] M. Z. I. Chowdhury *et al.*, “Prediction of hypertension using traditional regression and machine learning models: A systematic review and meta-analysis,” *PLoS One*, vol. 17, no. 4 April, 2022, doi: 10.1371/journal.pone.0266334.
- [5] C. Abbafati *et al.*, “Global burden of 87 risk factors in 204 countries and territories, 1990–2019: a systematic analysis for the Global Burden of Disease Study 2019,” *Lancet*, vol. 396, no. 10258, pp. 1223–1249, 2020, doi: 10.1016/S0140-6736(20)30752-2.
- [6] G. Parati *et al.*, “Home blood pressure monitoring: Methodology, clinical relevance and practical application: A 2021 position paper by the Working Group on Blood Pressure Monitoring and Cardiovascular Variability of the European Society of Hypertension,” *J. Hypertens.*, vol. 39, no. 9, pp. 1742–1767, 2021, doi: 10.1097/JHJ.0000000000002922.
- [7] J. S. Cho and J.-H. Park, “Application of artificial intelligence in hypertension,” pp. 1–9, 2024, doi: doi.org/10.1186/s40885-024-00266-9.
- [8] B. Jaltotage and G. Dwivedi, “Essentials for AI Research in Cardiology : Challenges and Mitigations,” *CJC Open*, vol. 6, no. 11, pp. 1334–1341, 2024, doi: 10.1016/j.cjco.2024.07.015.
- [9] S. F. Alam and M. L. G. Suarez, “Transforming Healthcare : The AI Revolution in the Comprehensive Care of Hypertension,” *Clin. Pract.*, pp. 1357–1374, 2024, doi: doi.org/10.3390/clinpract14040109.
- [10] P. Purwono *et al.*, “Model Prediksi Otomatis Jenis Penyakit Hipertensi dengan Pemanfaatan Algoritma Machine Learning Artificial Neural Network,” *INSECT*, vol. 7, no. 2, pp. 82–90, 2022, doi: doi.org/10.33506/insect.v7i2.1828.
- [11] J. Ganiev, D.-W. Kim, and S.-H. Bae, “Neural-NGBoost: Natural gradient boosting with neural network base learners,” *J. Ind. Inf. Integr.*, p. 100826, 2025, doi: 10.1016/j.jicte.2025.08.003.
- [12] R. Katarya and S. K. Meena, “Machine Learning Techniques for Heart Disease Prediction: A Comparative Study and Analysis,” *Health Technol. (Berl.)*, vol. 11, no. 1, pp. 87–97, 2021, doi: 10.1007/s12553-020-00505-7.
- [13] M. Diwakar, A. Tripathi, K. Joshi, M. Memoria, P. Singh, and N. Kumar, “Latest trends on heart disease prediction using machine learning and image fusion,” *Mater. Today Proc.*, vol. 37, no. Part 2, pp. 3213–3218, 2020, doi: 10.1016/j.matpr.2020.09.078.
- [14] H. Benhar, A. Idri, and J. L Fernández-Alemán, *Data*

- [15] preprocessing for heart disease classification: A systematic literature review., vol. 195. 2020. doi: 10.1016/j.cmpb.2020.105635.
- [16] L. Wang and K. Zuo, "Medical Data Classification Assisted by Machine Learning Strategy," *Comput. Math. Methods Med.*, vol. 2022, 2022, doi: 10.1155/2022/9699612.
- [17] M. Torres-Velázquez, W.-J. Chen, X. Li, and A. B. McMillan, "Application and Construction of Deep Learning Networks in Medical Imaging," *Physiol. Behav.*, vol. 176, no. 1, pp. 139–148, 2017, doi: 10.1109/trpms.2020.3030611.
- [18] L. Nieradzik, G. Scheuermann, D. Saur, and C. Gillmann, "Effect of the output activation function on the probabilities and errors in medical image segmentation," 2021, doi: doi.org/10.48550/arXiv.2109.00903.
- [19] J. Egger, A. Pepe, C. Gsaxner, Y. Jin, J. Li, and R. Kern, "Deep learning — a first meta survey of selected reviews across scientific disciplines , their commonalities , challenges and research impact," *PeerJ Comput. Sci.*, pp. 1–83, 2021, doi: 10.7717/peerj.cs.773.
- [20] E. Fikadu, T. Urgessa, and M. Das, "MLP-SVM: a hybrid approach for improving the performance of the classification model for health-related documents from social media using multi-layer perceptron and support vector machine," *Discov. Appl. Sci.*, vol. 7, no. 4, 2025, doi: 10.1007/s42452-025-06851-3.
- [21] M. M. Hasan, M. A. Hossain, A. Y. Srizon, and A. Sayeed, "TaLU: A Hybrid Activation Function Combining Tanh and Rectified Linear Unit to Enhance Neural Networks," pp. 1–15, 2023, [Online]. Available: <http://arxiv.org/abs/2305.04402>
- B. Swiderski, S. Osowski, G. Gwardys, J. Kurek, M. Slowinska, and I. Lugowska, "Random CNN structure: tool to increase generalization ability in deep learning," *Eurasip J. Image Video Process.*, vol. 2022, no. 1, 2022, doi: 10.1186/s13640-022-00580-y.