

Klasifikasi Penyakit Jantung Dengan Neural Network dan Seleksi Fitur Chi-Square

Ida Putu Ari Jayadinanta^{a1}, I Ketut Gede Suhartana^{a2}, Anak Agung Istri Ngurah Eka Karyawati^{a3},
I Gusti Ngurah Anom Cahyadi Putra^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana
Kuta Selatan, Badung, Bali, Indonesia

¹arijayadinanta24@gmail.com

²ikg.suhartana@unud.ac.id

³eka.karyawati@unud.ac.id

⁴anom.cp@unud.ac.id

Abstract

Heart disease is one of the leading causes of death globally, making early identification crucial. Artificial intelligence technology, particularly the Artificial Neural Networks (ANN), offers an efficient solution to the limitations of traditional diagnostic methods. This thesis aims to implement a classification model using ANN combined with the Chi-Square feature selection method to enhance accuracy in heart disease identification. The data used in this research is derived from relevant public datasets. The research process includes data collection, preprocessing, feature selection, model training, and result evaluation. The ANN model was trained using various hyperparameter scenarios, such as epoch, learning rate, and the batch size, to find the best configuration. The results indicate that the combination of ANN and Chi-Square feature selection improves heart disease classification accuracy, with the highest accuracy reaching 86%. This research contributes to the development of more efficient and accurate artificial intelligence-based diagnostic methods for heart disease identification.

Keywords: Neural Network, Feature Selection, Chi-Squared, Heart Disease, Classification.

1. Pendahuluan

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia. Berdasarkan data dari Organisasi Kesehatan Dunia WHO [1], lebih dari 17 juta kematian setiap tahunnya disebabkan oleh penyakit ini. Oleh karena itu, identifikasi dini penyakit jantung menjadi sangat penting untuk menekan angka kematian dan meningkatkan kualitas hidup pasien. Namun, metode diagnostik yang ada saat ini seringkali memerlukan peralatan yang mahal serta tenaga medis yang sangat terlatih. Kondisi ini mendorong perlunya pengembangan metode yang lebih efisien dan akurat dalam mendeteksi penyakit jantung.

Perkembangan teknologi kecerdasan buatan, khususnya dalam jaringan syaraf tiruan (JST), menawarkan solusi yang menjanjikan dalam menghadapi tantangan ini. JST memiliki kemampuan untuk mempelajari pola yang kompleks dari data medis dan melakukan prediksi yang akurat. Beberapa penelitian sebelumnya menunjukkan bahwa JST dapat digunakan dengan baik dalam prediksi penyakit jantung. Penelitian yang dilakukan oleh Galih Pradana et al. [2] menemukan bahwa model JST mampu mencapai akurasi sebesar 73,77% dalam klasifikasi penyakit jantung. Selain itu, penelitian Lutfia et al. [3] menunjukkan bahwa penggunaan algoritma Naïve Bayes yang dikombinasikan dengan seleksi fitur Gain Ratio mampu menghasilkan akurasi sebesar 91,2%, melampaui kinerja Naïve Bayes tanpa seleksi fitur. Penelitian lain yang dilakukan oleh Kamal & Ramdhani [4] menunjukkan bahwa seleksi fitur berbasis algoritma genetika mampu meningkatkan akurasi JST untuk prediksi curah hujan dari 77,99% menjadi 89,74%. Selain itu, penelitian oleh Santo et al. [5] yang menggunakan Deep Neural Network (DNN) yang dioptimalkan dengan metode seleksi fitur Chi-Square dan Particle Swarm Optimization (PSO) menunjukkan peningkatan akurasi dalam deteksi diabetes, dari 76,62% menjadi 85,71%.

Berdasarkan penelitian-penelitian tersebut, metode seleksi fitur Chi-Square terbukti mampu meningkatkan performa JST dalam berbagai aplikasi. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model klasifikasi JST yang dikombinasikan dengan metode seleksi fitur Chi-Square

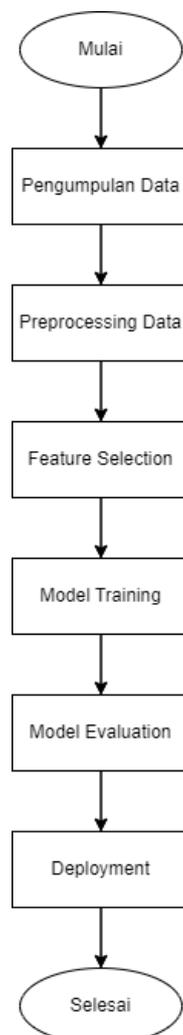
dalam mengidentifikasi penyakit jantung. Dalam penelitian ini, beberapa langkah yang akan dilakukan antara lain adalah mengimplementasikan model JST untuk klasifikasi penyakit jantung, menerapkan metode seleksi fitur Chi-Square untuk memilih fitur yang paling relevan dari data medis, dan melakukan eksperimen dengan berbagai konfigurasi hyperparameter JST, seperti learning rate dan epoch, serta variasi jumlah fitur yang dipilih oleh metode Chi-Square. Selain itu, model akan dievaluasi dengan menggunakan metrik seperti akurasi, precision, recall, dan F1-score untuk menilai seberapa baik kombinasi JST dan seleksi fitur Chi-Square dalam mendeteksi penyakit jantung.

Dengan langkah-langkah tersebut, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan metode identifikasi dini penyakit jantung yang lebih efisien dan akurat berbasis kecerdasan buatan.

2. Metodologi Penelitian

Penelitian ini menggunakan pendekatan eksperimen untuk mengembangkan dan menguji model jaringan syaraf tiruan (JST) dalam mendeteksi penyakit jantung. Tahapan penelitian meliputi pengumpulan dataset, preprocessing data, seleksi fitur, pelatihan model, serta evaluasi dan deployment. Setiap tahap dirancang secara sistematis guna memastikan hasil yang optimal dalam penerapan JST yang dikombinasikan dengan metode seleksi fitur Chi-Square.

2.1 Alur dan Desain Penelitian



Gambar 1. Alur Penelitian

Pada Gambar 1, Alur penelitian dimulai dari pengumpulan dataset, preprocessing data, seleksi fitur menggunakan metode Chi-Square, pelatihan model JST, tuning hyperparameter, dan evaluasi kinerja model. Pendekatan eksperimental ini memungkinkan peneliti untuk memanipulasi variabel yang

relevan guna mengamati pengaruhnya terhadap akurasi prediksi penyakit jantung. Evaluasi terhadap kombinasi JST dan metode seleksi fitur Chi-Square akan dilakukan dengan membandingkannya dengan model JST tanpa seleksi fitur. Melalui pendekatan ini, penelitian dapat menentukan efektivitas seleksi fitur dalam meningkatkan akurasi deteksi.

2.2 Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, yaitu "Heart Statlog Cleveland Hungary Final" (<https://www.kaggle.com/datasets/sid321axn/heart-statlog-cleveland-hungary-final>). Dataset ini mencakup 12 atribut yang relevan dengan prediksi penyakit jantung, seperti usia, jenis kelamin, tekanan darah, kadar kolesterol, dan lain-lain. Variabel target yang digunakan adalah status kesehatan pasien, yaitu apakah pasien memiliki penyakit jantung (1) atau tidak (0). Dataset ini telah dilabeli oleh ahli medis, yang menjamin validitas dan reliabilitas data.

Atribut-atribut yang digunakan dalam penelitian ini mencakup usia, jenis kelamin, tipe nyeri dada, tekanan darah istirahat, kadar kolesterol serum, gula darah puasa, hasil elektrokardiogram, denyut jantung maksimal, angina yang diinduksi olahraga, depresi ST akibat olahraga, kemiringan segmen ST, serta status penyakit jantung (sebagai variabel target). Pemilihan atribut didasarkan pada relevansi terhadap diagnosis penyakit jantung, sebagaimana telah divalidasi dalam penelitian terdahulu.

2.3 Data Preprocessing

Tahap preprocessing data terdiri dari beberapa langkah penting. Pertama, dilakukan deteksi dan penanganan outlier menggunakan metode Z-score untuk mengidentifikasi nilai-nilai yang menyimpang dari distribusi data normal. Nilai Z-score di atas 3 atau di bawah -3 dianggap sebagai outlier dan akan dianalisis lebih lanjut.

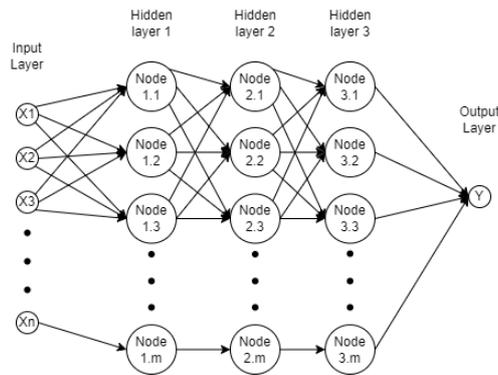
Selanjutnya, dilakukan normalisasi data untuk menyamakan skala antar fitur. Normalisasi dilakukan dengan mengubah nilai-nilai atribut ke dalam rentang antara 0 hingga 1 menggunakan rumus normalisasi. Ini penting untuk memastikan bahwa fitur-fitur dengan skala yang berbeda tidak memberikan bobot yang berlebihan dalam proses pelatihan model.

2.4 Seleksi Fitur

Seleksi fitur merupakan langkah penting untuk memilih atribut yang paling relevan terhadap prediksi penyakit jantung. Dalam penelitian ini, metode Chi-Square digunakan untuk menyeleksi fitur berdasarkan relevansinya dengan variabel target. Tiga skenario seleksi fitur akan diuji, yaitu dengan menggunakan 5 fitur teratas, 9 fitur teratas, dan semua fitur. Proses seleksi ini bertujuan untuk mengurangi kompleksitas data dan meningkatkan performa model. Menurut Ernayanti et al [6], banyaknya jumlah fitur menyebabkan data overload, menyimpang dan dapat mempengaruhi proses klasifikasi, sehingga perlu dilakukan seleksi fitur.

2.5 Pelatihan Model

Data yang telah diproses akan dibagi menjadi 80% untuk data pelatihan dan 20% untuk data pengujian. Model JST akan dibangun dengan tiga lapisan tersembunyi (hidden layers) sesuai dengan referensi dari penelitian terdahulu. Dua skenario arsitektur JST akan diuji, yaitu dengan jumlah node sebanyak 32 dan 16 pada setiap lapisan tersembunyi. Untuk arsitekturnya dapat dilihat pada gambar 2.



Gambar 2. Arsitektur Jaringan

Berdasarkan gambar 2, rancangan arsitektur akan memiliki 3 hidden layer.

3. Hasil dan Pembahasan

3.1. Preprocessing Data

Berdasarkan Gambar 3.1, proses penelitian ini dimulai dari tahap Pengumpulan Data. Setelah data terkumpul, langkah berikutnya adalah Preprocessing Data. Pada tahap ini, dua langkah utama yang dilakukan adalah penanganan data outlier dan normalisasi data.

a. Penanganan Data Outlier

Pada tahap pertama dalam preprocessing data, identifikasi data outlier dilakukan menggunakan metode Z-Score. Baris data yang memiliki Z-Score lebih dari 3 atau kurang dari -3 dianggap sebagai outlier dan akan dihapus. Fitur yang diuji dalam tahap ini adalah fitur numerik, yaitu usia (age), tekanan darah istirahat (resting bp), kolesterol (cholesterol), dan detak jantung maksimum (max heart rate). Deteksi outlier dilakukan dengan bantuan library SciPy dan Microsoft Excel.

Hasil yang didapat menunjukkan bahwa terdapat 17 baris data yang terdeteksi sebagai outlier. Data outlier ini diidentifikasi melalui analisis statistik untuk menemukan data yang tidak sesuai dengan pola umum dalam dataset. Setelah identifikasi selesai, baris-baris data yang dianggap outlier dihapus untuk meningkatkan kualitas analisis, sehingga jumlah data awal yang terdiri dari 1190 baris berkurang menjadi 1173 baris. Langkah ini diharapkan dapat menghasilkan model yang lebih baik.

b. Normalisasi Data

Tahap kedua dalam preprocessing adalah normalisasi data. Untuk data numerik, distribusi nilai masih belum merata. Hal ini disebabkan oleh rentang nilai yang sangat berbeda antar kolom, yang dapat mempengaruhi hasil analisis dan kinerja model. Kolom yang dinormalisasikan adalah usia (age), tekanan darah istirahat (resting bp), kolesterol (cholesterol), detak jantung maksimum (max heart rate), dan old peak.

Hasil normalisasi ditampilkan pada Tabel 1, menunjukkan bahwa setelah menggunakan MinMaxScaler, semua kolom memiliki distribusi yang lebih merata dan berada dalam

rentang yang sama. Hal ini memungkinkan model untuk memproses data dengan lebih efektif, serta mengurangi kemungkinan bias dari perbedaan skala antar fitur.

Tabel 1. Hasil Normalisasi

Age	Sex	Chest Pain type	Resting Blood Pressure	Cholesterol	Fasting Blood Sugar	Rest Ecg	Max Heart Rate Achieved	Exercise Induced Angina	St Depression	ST Slope
0.244898	1	2	0.571429	0.588595	0	0	0.777778	0	0.295455	1
0.428571	0	3	0.761905	0.366599	0	0	0.659259	0	0.409091	2
0.183673	1	2	0.476190	0.576375	0	1	0.229630	0	0.295455	1
0.408163	0	4	0.552381	0.435845	0	0	0.303704	1	0.465909	2
0.530612	1	3	0.666667	0.397149	0	0	0.407407	0	0.295455	1
...
0.346939	1	1	0.285714	0.537678	0	0	0.481481	0	0.431818	2
0.816327	1	4	0.609524	0.393075	1	0	0.548148	0	0.681818	2
0.591837	1	4	0.476190	0.266802	0	0	0.355556	1	0.431818	2
0.591837	0	2	0.476190	0.480652	0	2	0.792593	0	0.295455	2

3.2. Seleksi Fitur

Berdasarkan Gambar 1, tahap selanjutnya adalah seleksi fitur. Pada tahap ini, seleksi fitur dilakukan menggunakan metode Chi-Squared untuk mengidentifikasi fitur-fitur yang paling relevan dan signifikan terhadap target prediksi. Seleksi fitur ini penting untuk mengurangi dimensionalitas data, yang akan mempercepat proses komputasi dan meningkatkan akurasi model dengan menghilangkan fitur yang tidak relevan atau redundan.

Hasil seleksi fitur ditunjukkan pada Tabel 2. Dari hasil tersebut, fitur kolesterol (cholesterol) dan detak jantung maksimum (max heart rate) muncul sebagai dua fitur paling signifikan. Fitur lain seperti old peak, exercise angina, dan usia (age) juga berperan penting, meskipun dengan pengaruh yang lebih rendah. Fitur dengan skor rendah seperti jenis kelamin (sex), gula darah puasa (fasting blood sugar), dan tekanan darah istirahat (resting bp) masih dapat digunakan, tetapi kontribusinya terhadap prediksi mungkin tidak signifikan. Seleksi fitur ini menyederhanakan model dengan menggunakan fitur yang paling relevan, sehingga meningkatkan akurasi dan efisiensi model prediktif.

Tabel 2. Score dari Hasil Seleksi Fitur

Specs	Score
cholesterol	2287.694270
max heart rate	946.344830
oldpeak	251.638331
exercise angina	168.989554
age	133.084465
ST slope	69.732959
chest pain type	68.144590
resting bp s	44.751529
fasting blood sugar	43.951531
sex	27.225253

3.3. Model Training

Berdasarkan Gambar 1, tahap selanjutnya adalah model training. Langkah pertama dalam tahap ini adalah memisahkan data (splitting data) dan langkah kedua adalah melatih model (train model).

a. Split Data

Proses pertama dalam model training adalah memisahkan 80% dari keseluruhan dataset untuk keperluan pelatihan (training), sedangkan 20% sisanya digunakan sebagai data uji (testing). Data latih digunakan untuk membangun model dengan mempelajari hubungan antara fitur input dan target. Data uji digunakan untuk mengukur kemampuan generalisasi model terhadap data baru. Pembagian ini bertujuan untuk menghindari overfitting. Setelah pemisahan, 80% dari data latih dibagi kembali menjadi dua subset: 80% untuk pelatihan

akhir dan 20% untuk validasi. Data validasi digunakan untuk memantau kinerja model dan melakukan penyesuaian hyperparameter.

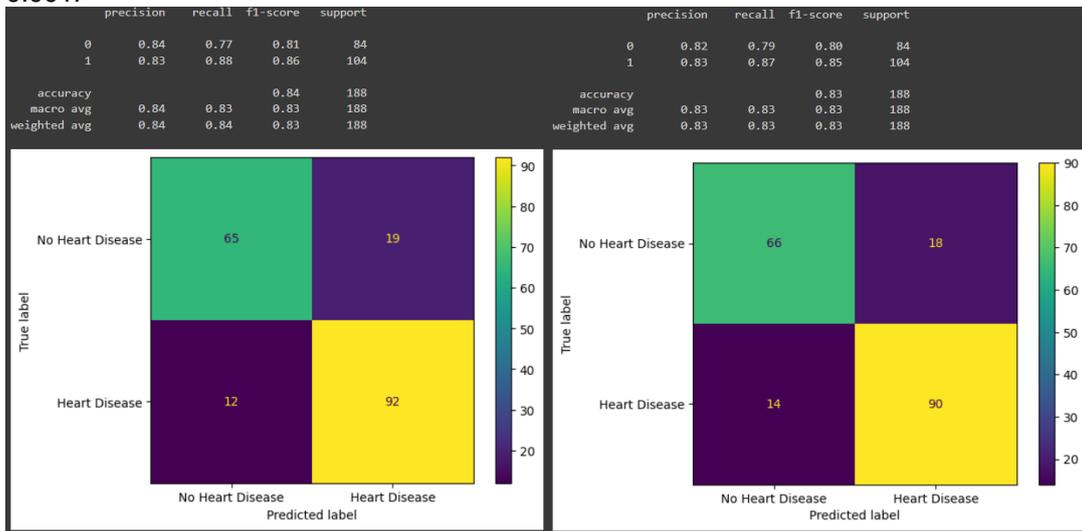
Dataset asli memiliki bentuk (1173, 12) dan setelah pemisahan, data latih terdiri dari 750 baris untuk melatih model, sedangkan data validasi berukuran (188, 11) dan data uji berukuran (235, 11).

b. Train Model

Tahap selanjutnya adalah model training. Langkah pertama dalam pelatihan model adalah membuat arsitektur model yang akan digunakan untuk proses pembelajaran.

3.4. Evaluasi Model

Berdasarkan Gambar 1, tahap berikutnya adalah evaluasi model. Beberapa skenario pengujian dilakukan untuk mengukur pengaruh jumlah node pada hidden layer terhadap performa model. Pada pengujian pertama, akurasi model dengan jumlah node yang berbeda (32 node dan 16 node) diuji dengan parameter yang sama: epoch = 100, batch size = 32, dan learning rate = 0.001.

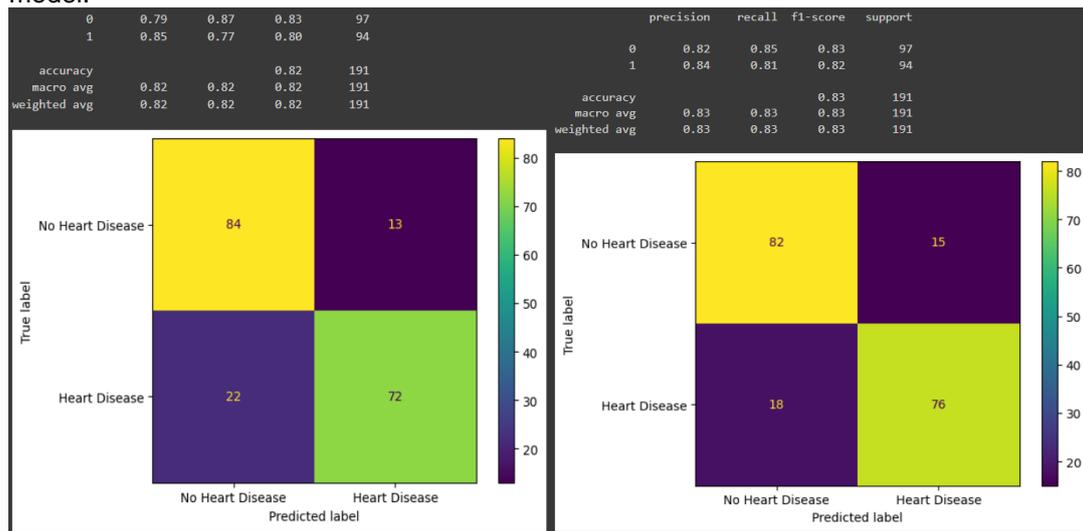


Gambar 3. Hasil Pengujian Skenario Pertama

Berdasarkan gambar 3, hasil pengujian pertama menunjukkan bahwa model dengan 32 node mencapai akurasi 84%, sementara model dengan 16 node memperoleh akurasi 83%. Meskipun perbedaannya kecil, hal ini menunjukkan bahwa model dengan lebih banyak node dapat menangkap lebih banyak pola dan fitur dalam data, sehingga meningkatkan kemampuan prediksi.

Pengujian kedua dilakukan dengan membandingkan akurasi berdasarkan jumlah fitur. Model diuji dengan menggunakan 5, 9, dan 11 fitur. Berdasarkan gambar 4, hasil evaluasi menunjukkan bahwa penggunaan 5 fitur menghasilkan akurasi 82%, sedangkan 9 fitur mencapai akurasi 83%, dan 11 fitur mencapai akurasi 84%. Ini menunjukkan bahwa jumlah fitur yang digunakan

mempengaruhi hasil prediksi, dan penggunaan fitur tambahan dapat meningkatkan akurasi model.



Gambar 4. Hasil Pengujian Skenario Kedua

Pengujian ketiga dilakukan dengan men-tuning hyperparameter (epoch, batch size, dan learning rate) dengan kombinasi yang berbeda. Hasil dari kombinasi hyperparameter ditampilkan pada Tabel 3. Terdapat 4 kombinasi yang mencapai akurasi tertinggi sebesar 86%.

Tabel 3. Hasil Pengujian Skenario Ketiga

NO	Epoch	Batch Size	Learning Rate	Akurasi
1	50	16	0.001	86%
2	50	32	0.001	83%
3	50	64	0.001	80%
4	100	16	0.001	83%
5	100	32	0.001	84%
6	100	64	0.001	84%
7	200	16	0.001	86%
8	200	32	0.001	83%
9	200	64	0.001	84%
10	50	16	0.01	82%
11	50	32	0.01	83%
12	50	64	0.01	84%
13	100	16	0.01	86%
14	100	32	0.01	84%
15	100	64	0.01	85%
16	200	16	0.01	85%
17	200	32	0.01	86%
18	200	64	0.01	83%
19	50	16	0.1	82%
20	50	32	0.1	80%
21	50	64	0.1	83%
22	100	16	0.1	80%
23	100	32	0.1	80%
24	100	64	0.1	79%
25	200	16	0.1	82%
26	200	32	0.1	83%
27	200	64	0.1	82%

Hasil eksperimen menunjukkan bahwa hyperparameter memengaruhi performa model. Epoch, batch size, dan learning rate memainkan peran penting dalam menentukan waktu pelatihan dan

akurasi. Kombinasi dengan epoch 50, batch size 16, dan learning rate 0,001 memberikan keseimbangan terbaik antara waktu pelatihan dan akurasi.

Secara keseluruhan, hasil ini menunjukkan bahwa pemilihan fitur dan konfigurasi model sangat penting dalam menentukan performa akhir. Meskipun penggunaan lebih banyak fitur dapat meningkatkan akurasi, model dengan konfigurasi node yang lebih kompleks memberikan hasil yang lebih baik. Evaluasi lebih lanjut dan penyesuaian dari kedua aspek—fitur dan arsitektur model—dapat membantu mengoptimalkan akurasi dan performa model secara keseluruhan.

4. Kesimpulan

Penelitian ini telah berhasil melakukan klasifikasi penyakit jantung menggunakan Neural Network. Berdasarkan analisis hasil penelitian, terdapat beberapa kesimpulan yang dapat diambil:

- a. Hasil pengujian menunjukkan bahwa perubahan jumlah node pada hidden layer dan pemilihan fitur menggunakan metode Chi-Square secara signifikan mempengaruhi akurasi model dalam mendeteksi penyakit jantung. Model dengan 32 node di hidden layer mencapai akurasi tertinggi sebesar 84%, sementara model dengan 16 node menghasilkan akurasi 83%. Selain itu, dengan menguji model menggunakan 5, 9, dan 11 fitur, ditemukan bahwa akurasi meningkat seiring bertambahnya jumlah fitur, dengan 9 fitur menghasilkan akurasi 83% dan 11 fitur memberikan hasil terbaik dengan akurasi 84%. Hal ini menunjukkan bahwa konfigurasi arsitektur model dan seleksi fitur memainkan peranan penting dalam meningkatkan akurasi.
- b. Metode seleksi fitur Chi-Square efektif dalam mengidentifikasi fitur-fitur yang relevan, yang pada akhirnya meningkatkan akurasi prediksi. Pengujian dengan jumlah fitur yang lebih sedikit (5 fitur) menghasilkan akurasi 82%, sedangkan penambahan jumlah fitur hingga 9 dan 11 meningkatkan akurasi hingga 84%. Ini menunjukkan bahwa fitur tambahan memberikan informasi yang lebih mendalam bagi model untuk mengenali pola yang relevan.
- c. Eksperimen dengan berbagai kombinasi hyperparameter mengungkapkan empat kombinasi yang mencapai akurasi tertinggi sebesar 86%. Meskipun parameter-parameter tersebut bervariasi, akurasi tetap konsisten pada angka tersebut. Kombinasi yang paling efisien berdasarkan analisis time complexity adalah konfigurasi dengan epoch 50, batch size 16, dan learning rate 0,001, yang tidak hanya mencapai akurasi tinggi tetapi juga memerlukan waktu pelatihan yang lebih singkat.

References

- [1]WHO, "Penyakit kardiovaskular (PKV)."
- [2]D. Galih Pradana, M. L. Alghifari, M. Farhan Juna, and S. Dwisiwi Palaguna, "Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network," *Indonesian Journal of Data and Science (IJODAS)*, vol. 3, no. 2, pp. 55–60, 2022.
- [3]A. Lutfia, R. Saepul Rohman, and A. Gunawan, "PENERAPAN SELEKSI FITUR GAIN RATIO PADA PREDIKSI PENYAKIT JANTUNG BERBASIS NAÏVE BAYES," *JURNAL RESPONSIF*, vol. 6, no. 1, pp. 1–10, 2024, [Online]. Available: <https://ejurnal.ars.ac.id/index.php/jti>
- [4]N. Kamal and Y. Ramdhani, "Optimasi Algoritma Neural Network berbasis Fitur Seleksi Menggunakan Algoritma Genetika Untuk Prediksi Curah Hujan," vol. 4, no. 2, 2023.
- [5]W. B. Santo, W. B. Santosa, and A. Syukur, "JURNAL MEDIA INFORMATIKA BUDIDARMA Pemilihan Fitur Menggunakan Algoritma Chi-Square Dan Particle Swarm Optimization (PSO) Untuk Meningkatkan Kinerja Deep Neural Network Pada Deteksi Penyakit Diabetes," 2024, doi: 10.30865/mib.v8i1.7277.
- [6]T. Ernayanti, M. Mustafid, A. Rusgiyono, and A. R. Hakim, "PENGUNAAN SELEKSI FITUR CHI-SQUARE DAN ALGORITMA MULTINOMIAL NAÏVE BAYES UNTUK ANALISIS SENTIMEN PELANGGAN TOKOPEDIA," *Jurnal Gaussian*, vol. 11, no. 4, pp. 562–571, Feb. 2023, doi: 10.14710/j.gauss.11.4.562-571.