

**IMPLEMENTASI NEURAL NETWORK UNTUK PREDIKSI PENYAKIT
JANTUNG DENGAN EXPLAINABLE AI**

SKRIPSI

Oleh :

DAFFA ZUHDI SYAHADA

NIM. 220605110053



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

**IMPLEMENTASI NEURAL NETWORK UNTUK PREDIKSI PENYAKIT
JANTUNG DENGAN EXPLAINABLE AI**

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
DAFFA ZUHDI SYAHADA
NIM. 220605110053

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN

**IMPLEMENTASI NEURAL NETWORK UNTUK PREDIKSI PENYAKIT
JANTUNG DENGAN EXPLAINABLE AI**

SKRIPSI

Oleh :
DAFFA ZUHDI SYAHADA
NIM. 220605110053

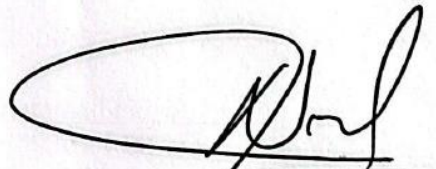
Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 10 Desember 2025

Pembimbing I,



Prof. Dr. Ir. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

Pembimbing II,



Dr. Ir. Fresy Nugroho, ST., MT., IPM,
ASEAN.Eng
NIP. 19710722 201101 1 001

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M.Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

**IMPLEMENTASI NEURAL NETWORK UNTUK PREDIKSI PENYAKIT
JANTUNG DENGAN EXPLAINABLE AI**

SKRIPSI

Oleh :
DAFFA ZUHDI SYAHADA
NIM. 220605110053

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 30 Maret 2026

Susunan Dewan Penguji
Ketua Penguji : Dr. Ir. Yunifa Miftachul Arif, M.T
NIP. 19830616 201101 1 004
Anggota Penguji I : Supriyono, M.Kom
NIP. 19841010 201903 1 012
Anggota Penguji II : Prof. Dr. Ir. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007
Anggota Penguji III : Dr. Ir. Fresy Nugroho, ST., MT., IPM,
ASEAN.Eng
NIP. 19710722 201101 1 001

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M.Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Daffa Zuhdi Syahada
NIM : 220605110053
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Implementasi Neural Network untuk Prediksi Penyakit Jantung Dengan Explainable AI

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 22 April 2026

Yang membuat pernyataan,



Daffa Zuhdi Syahada
NIM 220605110053

MOTTO

... Aku tidak akan menyerah pada sesuatu hal yang aku inginkan, dan aku akan mendapatkannya ...

HALAMAN PERSEMBAHAN

Segala puji bagi Allah Subhanahu Wa Ta'ala atas rahmat, karunia, dan pertolongan-Nya, sehingga penulis dapat menuntaskan skripsi ini.

Karya ini penulis persembahkan kepada:

Orang Tua Penulis,

Bapak Muhammad Ihwan Narwanto dan Ibu Wahyuni

Atas doa yang senantiasa mengiringi, kasih sayang, dan dukungannya

Dosen Pembimbing dan Dosen Penguji,

Atas ilmu, arahan, dan bimbingan yang diberikan selama proses penyusunan skripsi.

Teman-Teman Resur Family,

Atas dukungan dan kebersamaannya saat Menyusun skripsi.

Teman-Teman Angkatan 22,

Atas kebersamaan, Kerjasama dan waktu yang diberikan saat masa perkuliahan.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Alhamdulillahirabbilalamin, segala puji dan syukur senantiasa penulis panjatkan ke hadirat Allah subhanahu wa ta'ala atas berkat Rahmat, serta hidayah Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Implementasi Neural Network untuk Prediksi Penyakit Jantung Dengan Explainable AI” dengan baik dan lancar. Shalawat serta salam tetap tercurahkan kepada Nabi Muhammad SAW, yang telah membawa kita dari zaman kebodohan menuju zaman kebenaran yakni Islam dan zaman yang penuh dengan ilmu pengetahuan sebagaimana yang di rasakan pada saat ini. Dan semoga kita semua mendapat syafaatnya di hari akhir kelak, Aamiin.

Penulis mengucapkan rasa terima kasih yang begitu besar kepada seluruh pihak yang memberikan dukungan dan motivasi kepada penulis sehingga dapat menyelesaikan skripsi ini. Ucapan terima kasih ini penulis disampaikan kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CAHRM., CRMP, selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes, selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Supriyono, M.Kom, selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang sekaligus Anggota Penguji I yang telah membantu, memberikan saran dan masukan sepanjang proses, mulai dari seminar proposal sampai sidang skripsi.

4. Prof. Dr. Muhammad Faisal, M.T, selaku pembimbing I, yang telah dengan sabar dan penuh dedikasi meluangkan waktu untuk memberikan bimbingan, arahan, dan motivasi yang berharga selama proses penyusunan skripsi ini sehingga dapat di selesaikan dengan baik.
5. Dr. Ir. Fresy Nugroho, S.T., M.T., IPM., ASIAN.Eng, selaku pembimbing II, yang dengan baik telah memberikan arahan dan dengan baik juga meluruskan kesalahan saya saat menyusun skripsi ini.
6. Dr. Yunifa Miftachul Arif, M.T selaku Ketua Penguji yang telah memberikan banyak saran dan arahan dari seminar proposal hingga sidang skripsi.
7. Nia Faricha, S.Si selaku Admin Program Studi Teknik Informatika yang selalu sabar memberikan informasi, membantu, dan memberikan arahan selama perkuliahan dan proses penulisan skripsi ini.
8. Kedua Orang Tua Penulis, yang dengan penuh kasih tak pernah Lelah mengingatkan penulis untuk selalu mendekatkan diri kepada Allah, khususnya dalam menjaga sholat lima waktu, sosok orang tua yang selalu mengorbankan tenaga, waktu, bahkan kenyamanan dirinya demi membangun kebahagiaan dan masa depan anak-anaknya, kedua orang tua yang tak hanya jadi penyemangat, tetapi juga tempat berlabuh doa dan harapan, yang selalu percaya dan mendukung sepenuh hati agar anaknya tumbuh menjadi pribadi yang sukses, beriman, dan membanggakan.
9. Adik-Adik penulis, yang selalu sabar kepada kakaknya, yang selalu berjuang untuk masa depan masing-masing, semoga kalian kelak tumbuh

menjadi pribadi yang kuat, cerdas, dan selalu bahasia, serta selalu dalam lindungan Allah SWT.

10. Teman Teman seperjuangan “Resur Malang Family” yang telah menemani, memberikan semangat, saran dan dukungan selama proses penyelesaian skripsi ini, kehadiran kalian, baik melalu diskusi, canda tawa, maupun dukungan kalian, menjadi salah satu penguat dalam perjalanan ini.
11. Seluruh warga Teknik Informatika khususnya Angkatan 2022 “Infinity” yang telah membantu, memotivasi, dan memberikan dukungan kepada penulis.
12. Teman Teman Himatif Encoder, Khususnya Divisi Media dan Informasi 22 maupun 23 yang telah memberikan semangat, dukungan, canda dan tawa, serta pengalaman untuk mengembangkan diri dan membuat perkuliahan menjadi menarik.
13. Kepada Kota Malang dan seluruh kisah yang hidup di dalamnya, tempat penulis menempuh perkuliahan di tanah perantauan, kota yang bukan sekadar menjadi ruang singgah, melainkan sebagai rumah yang hangat. Di dalamnya terukir berbagai kenangan, perjalanan penuh suka dan duka, tawa yang menguatkan, serta jatuh bangun yang membentuk penulis hingga berada di titik ini.
14. Untuk diri sendiri, yang telah melalui banyak proses, jatuh, bangkit, jatuh dan selalu bangkit, lelah namun tetap berjalan kedepan. Terima kasi telah bertahan sejauh ini, terus belajar, dan tidak menyerah meski kadang ingin

berhenti. Semoga tetap konsisten dalam hal baik, terus belajar dari kesalahan, terus berproses, dan tidak lupa tujuan awal.

Wassalamu'alaikum Wr, Wb.

Malang, 16 April 2026

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iii
PERNYATAAN KEASLIAN TULISAN	iv
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	xii
DAFTAR GAMBAR.....	xiv
DAFTAR TABEL	xv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	7
1.3 Batasan Masalah.....	7
1.4 Tujuan Penelitian.....	7
1.5 Manfaat Penelitian.....	8
BAB II STUDI PUSTAKA	9
2.1 Penelitian Terkait	9
2.2 Penyakit Jantung	12
2.3 Artificial Intelligence dan Machine Learning	15
2.4 Neural Network.....	15
2.4.1 Arsitektur Multi-Layer Perceptron.....	16
2.4.2 Fungsi Aktivasi	18
2.5 Explainable AI dan SHAP.....	20
2.5.1 Model Interpretabilitas dengan SHAP	23
2.5.2 Perhitungan Shapley Value	24
2.6 Evaluasi model	25
BAB III METODOLOGI PENELITIAN	28
3.1 Pendahuluan	28
3.2 Desain Penelitian.....	28
3.3 Persiapan Data.....	30
3.4 Preprocessing Data	33
3.5 Pembagian Dataset	36
3.6 Perancangan Model Multi-Layer Perceptron (MLP)	37
3.7 Training dan Validation Model MLP	40
3.8 Evaluasi	41
3.9 Interpretasi Model Menggunakan SHAP	42
3.9.1 Input Data.....	43
3.9.3 Perhitungan Nilai Shapley	44
3.9.4 Visualisasi dan Analisis Interpretasi SHAP	44
3.10 Output.....	45
3.11 Skenario Pengujian.....	45
BAB IV HASIL DAN PEMBAHASAN	47
4.1 Dataset.....	47

4.2 Hasil Preprocessing	47
4.2.1 Data Cleaning.....	47
4.2.2 Encoding	48
4.2.3 Normalisasi	51
4.3 Hasil	53
4.3.1 Hasil Skenario 1	54
4.3.2 Hasil Skenario 2.....	59
4.3.3 Hasil Interpretasi SHAP.....	64
4.4 Pembahasan	69
4.4.1 Hasil Pengaruh Variasi Arsitektur dan Fungsi Aktivasi	69
4.4.2 Analisis Performa Model	72
4.4.3 Analisis Interpretasi	73
4.5 Integrasi Islam dan Sains.....	74
BAB V KESIMPULAN DAN SARAN	77
5.1 Kesimpulan.....	77
5.2 Saran	78
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Arsitektur Model MLP	18
Gambar 2.2 Arsitektur SHAP	22
Gambar 3.1 Diagram Desain Penelitian.....	29
Gambar 3.2 Diagram Preprocessing	33
Gambar 3.3 Arsitektur Model MLP	37
Gambar 3.4 Perancangan Model Multi-Layer Preception	38
Gambar 3.5 Diagram Interpretasi SHAP	43
Gambar 4.1 Haisl Data Setelah Cleaning.....	48
Gambar 4.2 Grafik Hasil Training and Validation Loss	60
Gambar 4.3 Grafik Hasil Training and Validation Accuracy	61
Gambar 4.4 Confusion Matrix	62
Gambar 4.5 ROC-AUC.....	63
Gambar 4.6 Interpretasi Global.....	65
Gambar 4.7 Interpretasi Lokal	66

DAFTAR TABEL

Tabel 2.1 Ringkasan Penelitian Terdahulu	9
Tabel 3.1 Struktur Dataset Penyakit Jantung	31
Tabel 3.2 Contoh Dataset setelah melalui proses encoding dan normalisasi.....	35
Tabel 3.3 Skenario Pengujian	45
Tabel 4.1 Hasil Encoding	50
Tabel 4.2 Hasil Normalisasi.....	52
Tabel 4.3 Konfigurasi Eksperimen MLP	55
Tabel 4.4 Hasil Eksperimen	56
Tabel 4.5 Hasil Eksperimen Fungsi Aktivasi.....	58
Tabel 4.6 Hasil Laporan Klasifikasi.....	62

ABSTRAK

Syahada, Daffa Zuhdi. 2026. **Implementasi Neural Network Untuk Prediksi Penyakit Jantung dengan Explainable AI**. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Muhammad Faisal, M.T (II) Dr. Ir. Fresy Nugroho, ST., MT., IPM., ASEAN.Eng

Kata kunci: Penyakit Jantung, Neural network, Explainable AI

Penyakit jantung merupakan salah satu penyebab utama kematian dengan prevalensi yang terus meningkat, sehingga diperlukan metode deteksi dini yang akurat dan dapat dipercaya. Penelitian ini mengimplementasikan Neural Network berbasis Multi-Layer Perceptron (MLP) untuk memprediksi penyakit jantung serta mengintegrasikan Explainable Artificial Intelligence (XAI) menggunakan metode SHAP (Shapley Additive Explanations) guna meningkatkan transparansi hasil prediksi. Dataset yang digunakan adalah Heart Disease Dataset dari Kaggle yang terdiri dari 303 data pasien dengan 14 atribut medis, yang diproses melalui tahapan preprocessing, pembagian data, pelatihan model, dan evaluasi. Hasil pengujian menunjukkan bahwa model MLP mampu mencapai akurasi sebesar 90%, nilai F1-score 0,90, serta AUC-ROC 0,96, yang menandakan kemampuan klasifikasi yang sangat baik. Selain itu, metode SHAP berhasil mengidentifikasi fitur-fitur medis yang paling berpengaruh terhadap prediksi risiko penyakit jantung baik secara global maupun lokal, sehingga model yang dihasilkan tidak hanya akurat tetapi juga interpretatif dan dapat dipahami. Penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan medis berbasis kecerdasan buatan yang transparan dan aplikatif dalam bidang kesehatan.

ABSTRACT

Syahada, Daffa Zuhdi. 2025. **Implementasi Neural Network Uuntuk Prediksi Penyakit Jantung dengan Explainable AI**. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Muhammad Faisal, M.T (II) Dr. Ir. Fresy Nugroho, ST., MT., IPM., ASEAN.Eng

Keywords: Heart Disease, Neural Network, Explainable AI

Heart disease ranks among the primary causes of death globally, with its growing incidence underscoring the necessity for precise and dependable early detection strategies. This research employs a Neural Network that utilizes a Multi-Layer Perceptron (MLP) architecture to forecast heart disease and incorporates Explainable Artificial Intelligence (XAI) via the SHAP (Shapley Additive Explanations) technique to bolster the clarity of prediction outcomes. The research utilizes the Heart Disease Dataset sourced from Kaggle, which contains 303 patient entries featuring 14 different medical characteristics. These entries underwent various stages, including data preprocessing, division of the dataset, training of the model, and assessment. The findings from the experiments reveal that the MLP approach attained an accuracy rate of 90%, an F1-score of 0.90, and an AUC-ROC score of 0.96, reflecting excellent classification efficacy. Additionally, the SHAP technique adeptly elucidates the impact of significant medical features at both overarching and individual scales, rendering the model not only precise but also understandable and reliable. This research is anticipated to contribute to the advancement of transparent and effective AI-driven medical decision-making systems in the field of healthcare.

البحث مستخلص

شهادة، دفة زهدي. 2026. تطبيق الشبكة العصبية للتنبؤ بأمراض القلب باستخدام الذكاء الاصطناعي القابل للتفسير. البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: أ. د. محمد فيصل، الماجستير؛ المشرف الثاني: د. فريسي نغروهو، الماجستير.

الكلمات الرئيسية: أمراض قلب، شبكة عصبية، ذكاء اصطناعي قابل لتفسير

يُعدّ مرض القلب أحد الأسباب الرئيسية للوفاة مع زيادة مستمرة في الانتشار، مما يستدعي وجود أساليب دقيقة وموثوقة للكشف المبكر. ينفذ هذا البحث شبكة عصبية تعتمد على الإدراك متعدد الطبقات (MLP) للتنبؤ بأمراض القلب، وتدمج الذكاء الاصطناعي القابل للتفسير (XAI) باستخدام طريقة SHAP (تفسيرات شابلية التراكمية) لزيادة شفافية نتائج التنبؤ. مجموعة البيانات المستخدمة هي Heart Disease Dataset من Kaggle، والتي تتكون من 303 بيانات للمرضى مع 14 سمة طبية، وتمت معالجتها من خلال مراحل المعالجة المسبقة، وتقسيم البيانات، وتدريب النموذج، والتقييم. أظهرت نتائج الاختبار أن نموذج MLP قادر على تحقيق دقة بلغت 90%، وقيمة ف1 0.90، و 0.96 AUC-ROC مما يشير إلى قدرة تصنيفية ممتازة. بالإضافة إلى ذلك، نجحت طريقة SHAP في تحديد الميزات الطبية الأكثر تأثيراً في توقع مخاطر أمراض القلب سواء على المستوى العام أو المحلي، وبالتالي فإن النموذج الناتج ليس دقيقاً فحسب بل قابل للتفسير والفهم أيضاً. ومن المتوقع أن يشكل هذا البحث أساساً لتطوير أنظمة دعم اتخاذ القرار الطبي المستندة إلى الذكاء الاصطناعي والتي تكون شفافة وقابلة للتطبيق في مجال الصحة.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penyakit jantung merupakan salah satu penyebab utama kematian dengan prevalensi yang terus meningkat setiap tahun. Secara global, lebih dari 17 juta orang meninggal akibat penyakit kardiovaskular, dan 85% di antaranya disebabkan oleh serangan jantung serta stroke (Muharram et al., 2024). Di Indonesia sendiri, prevalensi penyakit jantung koroner pada populasi usia kerja juga menunjukkan angka yang signifikan dan mengalami peningkatan dalam satu dekade terakhir, sehingga menjadikannya salah satu penyebab utama kematian setelah stroke (Uli et al., 2020). Kondisi ini menegaskan bahwa penyakit jantung merupakan masalah kesehatan masyarakat yang sangat serius dan memerlukan perhatian khusus.

Deteksi dini penyakit jantung memiliki peran krusial dalam upaya pencegahan komplikasi dan penurunan angka kematian, terutama pada individu yang belum menunjukkan gejala klinis yang jelas. Dalam praktik medis, deteksi dini umumnya dilakukan melalui evaluasi data klinis pasien seperti usia, tekanan darah, kadar kolesterol, kadar gula darah, serta riwayat penyakit, yang bertujuan untuk mengidentifikasi tingkat risiko penyakit jantung sebelum kondisi berkembang menjadi lebih serius. Hasil deteksi ini kemudian digunakan sebagai dasar pertimbangan tenaga medis dalam menentukan kebutuhan pemeriksaan lanjutan maupun intervensi medis yang tepat. Namun, proses analisis data medis tersebut masih sering dilakukan secara manual berdasarkan interpretasi gejala dan

hasil pemeriksaan laboratorium, sehingga menghadapi berbagai kendala seperti keterbatasan waktu, potensi perbedaan penilaian antar tenaga medis, serta risiko kesalahan manusia dalam mengolah data pasien yang kompleks dan multidimensional (Ahsan & Siddique, 2022). Kondisi ini menunjukkan perlunya pendekatan berbasis teknologi yang mampu mendukung proses deteksi dini penyakit jantung secara lebih cepat, objektif, dan konsisten.

Dalam mendukung proses deteksi dini penyakit jantung berbasis data klinis, diperlukan suatu model komputasi yang mampu menganalisis hubungan kompleks antar variabel medis secara akurat. Salah satu pendekatan yang berpotensi digunakan sebagai alat bantu deteksi adalah *Neural Network* (NN). Algoritma ini memiliki kemampuan untuk mempelajari pola non-linear dari data berdimensi tinggi, sehingga sesuai untuk menganalisis karakteristik medis pasien seperti tekanan darah, kadar kolesterol, indeks massa tubuh, usia, serta riwayat penyakit keluarga.

Dengan kemampuan tersebut, *Neural Network* dapat membantu mengidentifikasi tingkat risiko penyakit jantung pada tahap awal, sehingga berfungsi sebagai sistem pendukung keputusan bagi tenaga medis dalam proses deteksi dan evaluasi risiko pasien. Beberapa penelitian menunjukkan bahwa model *Neural Network* mampu memberikan tingkat akurasi yang lebih baik dibandingkan metode konvensional maupun algoritma *machine learning* klasik dalam konteks prediksi risiko penyakit jantung (Yuda Syahidin et al., 2022).

Meskipun *Neural Network* mampu memberikan hasil deteksi risiko penyakit jantung dengan tingkat akurasi yang baik, model ini memiliki keterbatasan

dalam aspek interpretabilitas karena mekanisme pengambilan keputusannya sulit dipahami secara langsung. Dalam konteks deteksi penyakit jantung, keterbatasan ini menjadi tantangan penting karena tenaga medis membutuhkan penjelasan yang jelas dan rasional mengenai faktor-faktor medis yang memengaruhi hasil deteksi (Permana et al., 2024).

Oleh karena itu, diperlukan pendekatan *Explainable Artificial Intelligence* (XAI) untuk meningkatkan transparansi hasil deteksi yang dihasilkan oleh model. Salah satu metode XAI yang relevan adalah SHAP (Shapley Additive exPlanations), yang mampu menjelaskan kontribusi masing-masing variabel medis terhadap hasil deteksi risiko penyakit jantung pada setiap pasien (Rahmada & Susanto, 2025). Dengan adanya penjelasan ini, tenaga medis tidak hanya memperoleh informasi mengenai status risiko pasien, tetapi juga memahami faktor medis dominan yang mendasari hasil deteksi tersebut, sehingga hasil model dapat dipercaya dan dimanfaatkan sebagai dasar pertimbangan keputusan klinis (Rizky Putri Soewarno et al., 2023).

Sejumlah penelitian sebelumnya telah menggunakan algoritma machine learning seperti *Decision Tree*, *Logistic Regression*, dan *Long Short Term Memory* (LSTM) untuk prediksi penyakit jantung. Namun, model tersebut masih terbatas dalam menangkap kompleksitas data medis sehingga akurasi belum maksimal (Muhammad Akram Fais et al., 2023). Penelitian yang menggunakan *Neural Network* memang menunjukkan hasil akurasi yang lebih baik, tetapi sebagian besar hanya berfokus pada aspek performa prediksi tanpa memberikan penjelasan mendalam mengenai interpretabilitas hasil model (Muharram et al., 2024). Kondisi

ini menimbulkan adanya kesenjangan penelitian, yaitu kebutuhan akan model prediksi penyakit jantung yang tidak hanya mengutamakan akurasi, tetapi juga menyediakan penjelasan yang jelas mengenai faktor-faktor medis yang berpengaruh terhadap hasil prediksi.

Berdasarkan hal tersebut, penelitian ini menawarkan kontribusi yang penting, yakni dengan mengimplementasikan *Neural Network* sebagai model prediksi penyakit jantung sekaligus mengintegrasikan metode SHAP sebagai pendekatan *Explainable AI*. Kontribusi penelitian ini dapat dirinci sebagai berikut: (1) menghadirkan model prediksi berbasis *Neural Network* yang mampu mendeteksi kemungkinan penyakit jantung dengan tingkat akurasi yang baik, (2) menyediakan interpretasi yang transparan melalui metode SHAP sehingga hasil prediksi dapat dipahami oleh tenaga medis maupun peneliti, dan (3) mendukung pengembangan sistem pendukung keputusan medis (*decision support system*) yang modern, cepat, dan aplikatif untuk meningkatkan kualitas layanan kesehatan di Indonesia (So et al., 2021). Dengan demikian, penelitian mengenai Implementasi *Neural Network* untuk Prediksi Penyakit Jantung dengan *Explainable AI* tidak hanya memberikan kontribusi akademis pada pengembangan sistem cerdas, tetapi juga memiliki dampak praktis yang signifikan dalam dunia Kesehatan (Mathur et al., 2020).

Selain itu, masalah kesehatan seperti penyakit jantung juga dapat dipandang dari perspektif keagamaan. Bagi seorang penderita, penyakit ini merupakan ujian yang membutuhkan kesabaran, sebagaimana Allah Subhanahu Wa Ta'ala berfirman dalam Al-Qur'an Surah Al-Baqarah ayat 155:

وَلَنَبْلُوَنَّكُمْ بِشَيْءٍ مِّنَ الْخَوْفِ وَالْجُوعِ وَنَقْصٍ مِّنَ الْأَمْوَالِ وَالْأَنْفُسِ وَالثَّمَرَاتِ وَبَشِّرِ الصَّابِرِينَ

“Dan sungguh akan Kami berikan cobaan kepadamu, dengan sedikit ketakutan, kelaparan, kekurangan harta, jiwa dan buah-buahan. Dan sampaikanlah kabar gembira kepada orang-orang yang sabar.” (QS. Al-Baqarah: 155).

Menurut tafsir Ibnu Katsir, ayat ini menjelaskan bahwa Allah akan menguji manusia dengan berbagai macam bentuk cobaan, baik yang berkaitan dengan kondisi psikologis (rasa takut), kondisi fisik (lapar, sakit), materi (harta), maupun kehilangan jiwa dan hasil usaha. Tujuannya adalah untuk menampakkan kualitas keimanan manusia, yakni siapa yang mampu bersabar dan tetap istiqamah dalam menghadapi cobaan, serta siapa yang bersyukur ketika mendapat nikmat. Orang yang sabar dalam menghadapi musibah akan memperoleh kabar gembira berupa pahala besar dari Allah (Ibnu Katsir & Ismail bin Umar., 2003).

Dalam konteks penyakit jantung, ayat ini mengajarkan bahwa penyakit tersebut adalah bentuk ujian yang menuntut kesabaran serta penerimaan terhadap ketentuan Allah. Namun, kesabaran ini tidak berarti pasrah tanpa usaha, melainkan harus disertai dengan ikhtiar untuk mencari kesembuhan dan menjaga kesehatan. Selanjutnya, Allah juga menegaskan dalam Surah Al-Baqarah ayat 195:

وَأَنْفِقُوا فِي سَبِيلِ اللَّهِ وَلَا تُلْقُوا بِأَيْدِيكُمْ إِلَى التَّهْلُكَةِ وَأَحْسِنُوا إِنَّ اللَّهَ يُحِبُّ الْمُحْسِنِينَ

“Dan janganlah kamu menjatuhkan dirimu sendiri ke dalam kebinasaan, dan berbuat baiklah, karena sesungguhnya Allah menyukai orang-orang yang berbuat baik.” (QS. Al-Baqarah: 195).

Menurut tafsir Al-Ṭabarī, larangan “menjatuhkan diri ke dalam kebinasaan” bermakna bahwa manusia dilarang melakukan sesuatu yang dapat merugikan dan membinasakan dirinya, baik dengan mengabaikan kewajiban, meninggalkan

ikhtiar, maupun membiarkan diri dalam kelalaian. Tafsir Ibnu Katsir menambahkan bahwa ayat ini juga mencakup perintah untuk menjaga diri dan memelihara kehidupan, sebab merusak diri sendiri adalah bentuk pengkhianatan terhadap amanah Allah berupa tubuh dan jiwa (Ibnu Katsir & Ismail bin Umar., 2003).

Ayat ini relevan dalam konteks kesehatan karena mengandung prinsip pencegahan dan perawatan diri. Upaya menjaga kesehatan, menghindari gaya hidup yang membahayakan, serta melakukan deteksi dini penyakit jantung merupakan bagian dari kewajiban manusia untuk tidak menjatuhkan dirinya ke dalam kebinasaan. Selain itu, dalam Islam menjaga kesehatan merupakan bagian dari perintah agama. Rasulullah SAW bersabda:

لِكُلِّ دَاءٍ دَوَاءٌ فَإِذَا أُصِيبَ دَوَاءُ الدَّاءِ بَرَأَ بِإِذْنِ اللَّهِ

"Sesungguhnya setiap penyakit ada obatnya. Maka apabila obat itu mengenai penyakit, ia akan sembuh dengan izin Allah 'Azza wa Jalla." (HR. Muslim No. 2204).

Hadis ini menunjukkan pentingnya ikhtiar dalam mencari solusi medis, termasuk pemanfaatan ilmu pengetahuan dan teknologi seperti kecerdasan buatan (*Artificial Intelligence*) untuk mendukung diagnosis dini penyakit, termasuk penyakit jantung. Dengan demikian, penelitian ini sejalan dengan nilai Islam yang mendorong pemeliharaan kesehatan (*hifzh al-nafs*) sebagai salah satu tujuan utama syariat (*maqāṣid al-syarī'ah*).

Dengan demikian, ayat dan hadist tersebut menegaskan adanya integrasi antara nilai spiritual dan upaya ilmiah dalam menghadapi penyakit. Penelitian tentang deteksi dini penyakit jantung melalui pemanfaatan teknologi modern dapat dipandang sebagai bentuk ikhtiar ilmiah yang selaras dengan perintah Allah untuk

menjaga diri, berbuat baik, serta bersabar dalam menghadapi ujian kehidupan. Hal ini menunjukkan bahwa ikhtiar medis tidak hanya bernilai praktis, tetapi juga memiliki dimensi spiritual yang mendalam.

1.2 Rumusan Masalah

Bagaimana mengimplementasikan metode *Neural Network* dengan pendekatan *Explainable AI* (SHAP) untuk memprediksi penyakit jantung berdasarkan data medis pasien secara akurat dan dapat dipahami oleh tenaga medis?

1.3 Batasan Masalah

Berikut batasan masalah yang digunakan dalam penelitian ini:

- a) Data yang digunakan dalam penelitian ini adalah data publik yang diambil dari Kaggle Heart Disease Prediction.
- b) Penelitian ini hanya berfokus pada pengolahan data sekunder (dataset yang sudah tersedia), tanpa melakukan pengumpulan data primer dari rumah sakit atau pasien secara langsung.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk mengimplementasikan metode *Neural Network* dengan pendekatan *Explainable AI* (SHAP) dalam memprediksi penyakit jantung berdasarkan data medis pasien, sehingga dihasilkan model yang akurat sekaligus transparan dan dapat membantu tenaga medis dalam memahami faktor-faktor medis yang memengaruhi hasil prediksi.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat dalam beberapa aspek. Dari sisi akademis, penelitian ini dapat memperkaya kajian di bidang *Artificial Intelligence*, khususnya mengenai penerapan *Neural Network* dalam prediksi penyakit jantung serta pemanfaatan *Explainable AI (XAI)* untuk meningkatkan transparansi model. Dari sisi praktis, penelitian ini dapat membantu tenaga medis dalam melakukan deteksi dini penyakit jantung dengan dukungan sistem prediksi yang lebih akurat dan dapat dipahami faktor-faktor medis yang memengaruhinya. Dengan demikian, hasil penelitian ini diharapkan dapat menjadi salah satu langkah awal dalam pengembangan sistem pendukung keputusan medis berbasis AI yang tidak hanya akurat tetapi juga dapat dipercaya oleh penggunanya.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Sejumlah penelitian telah mengkaji pemanfaatan kecerdasan buatan (*Artificial Intelligence*) dalam bidang kesehatan, khususnya prediksi penyakit jantung. Ringkasan penelitian terdahulu ditampilkan pada Tabel 2.1 berikut:

Tabel 2.1 Ringkasan Penelitian Terdahulu

No	Sitasi	Metode	Dataset	Hasil Utama
1.	Danu & Agung (2025)	Artificial Neural Network (ANN)	Data pasien RSUD Zainoel Abidin Banda Aceh (data klinis: usia, kolesterol, tekanan darah, dll.)	Model ANN mampu memprediksi risiko penyakit jantung koroner dengan akurasi tinggi dan mengenali pola klinis pasien berisiko.
2.	Raharjo et al. (2025)	ANN dengan variasi fungsi aktivasi (ReLU, Sigmoid, Tanh)	Dataset medis pasien gagal jantung	Fungsi aktivasi ReLU memberikan performa paling optimal, mempercepat konvergensi, dan meningkatkan akurasi model.
3.	Shaaf (2023)	Convolutional Neural Network (CNN)	Dataset MRI jantung (Left Ventricle Segmentation)	CNN berhasil mendeteksi kelainan bentuk ventrikel kiri dan mengidentifikasi potensi infark miokard dengan presisi tinggi.
4.	Miranda et al. (2023)	Machine Learning + SHAP	Rekam medis elektronik (EHR) pasien penyakit arteri jantung	SHAP menjelaskan pengaruh fitur seperti usia, kolesterol, dan tekanan darah terhadap hasil prediksi, meningkatkan interpretabilitas model.
5.	Abdellatif (2024)	Autoencoder + SHAP	Dataset UCI Heart Disease	Integrasi SHAP meningkatkan transparansi model Autoencoder dan mengidentifikasi fitur dominan dalam prediksi penyakit jantung.

No	Sitasi	Metode	Dataset	Hasil Utama
6.	Damayanti (2025)	Deep Neural Network (DNN) + PCA + SHAP & LIME	Data medis pasien koroner (hasil reduksi PCA)	Kombinasi PCA dan XAI (SHAP & LIME) meningkatkan interpretabilitas model DNN dan pemahaman pengaruh fitur terhadap hasil klasifikasi.

Penelitian mengenai penerapan kecerdasan buatan dalam bidang kesehatan, khususnya dalam mendeteksi penyakit jantung, telah banyak dilakukan oleh berbagai peneliti. (Danu & Agung, 2025) melakukan penelitian berjudul Rancangan Model *Artificial Neural Network* untuk Memprediksi Penyakit Jantung Koroner di RSUD Zainoel Abidin Banda Aceh. Penelitian ini membangun model *Artificial Neural Network* (ANN) yang memanfaatkan atribut klinis seperti tekanan darah, kolesterol, dan usia untuk memprediksi risiko penyakit jantung koroner. Hasil penelitian menunjukkan bahwa ANN mampu mengenali pola data medis dengan baik dan memberikan prediksi risiko penyakit dengan akurasi tinggi. Studi ini menjadi dasar penting bagi pengembangan sistem prediksi penyakit berbasis jaringan saraf tiruan.

(Raharjo et al., 2025) dalam penelitiannya yang berjudul Optimasi Fungsi Aktivasi pada *Artificial Neural Network* untuk Prediksi Gagal Jantung Secara Akurat menyoroti pentingnya pemilihan fungsi aktivasi dalam meningkatkan performa jaringan saraf tiruan. Penelitian ini membandingkan beberapa fungsi aktivasi seperti ReLU, sigmoid, dan tanh, dan menemukan bahwa penggunaan ReLU memberikan hasil paling optimal pada data medis. Temuan ini memperkuat pentingnya pemilihan arsitektur dan fungsi aktivasi yang sesuai dalam membangun model Neural Network untuk prediksi penyakit jantung.

Selain itu, (Shaaf, 2023) mengusulkan pendekatan berbasis Convolutional Neural Network (CNN) dalam penelitian berjudul *Convolutional Neural Network Model for Left Ventricle Segmentation to Detect Myocardial Infarction*. Penelitian ini menggunakan citra MRI jantung untuk mendeteksi infark miokard melalui segmentasi ventrikel kiri. Hasilnya menunjukkan bahwa CNN efektif dalam mengidentifikasi kelainan bentuk jantung, memperluas penerapan Neural Network dari data tabular menuju analisis citra medis yang lebih kompleks.

Berbagai penelitian terbaru juga mulai mengintegrasikan pendekatan *Explainable Artificial Intelligence (XAI)*, khususnya metode SHAP (Shapley Additive Explanations), untuk meningkatkan transparansi model prediksi medis. (Muliani et al., 2025) dalam penelitiannya berjudul *Understanding Arteriosclerotic Heart Disease Patients Using Electronic Health Records: A Machine Learning and SHAP Approach* menerapkan algoritma SHAP untuk menjelaskan hasil prediksi penyakit arteri jantung berdasarkan rekam medis elektronik. Melalui interpretasi nilai SHAP, penelitian ini mampu mengungkap kontribusi setiap fitur terhadap hasil prediksi, seperti tekanan darah dan kadar kolesterol, sehingga hasil model menjadi lebih mudah dipahami oleh tenaga medis.

(Abdellatif, 2024) dalam disertasinya *Enhanced Computational Methods for Detection and Interpretation of Heart Disease Based on Ensemble Learning and Autoencoder Framework* menggabungkan model *Autoencoder* dengan algoritma SHAP untuk mendeteksi penyakit jantung. SHAP digunakan untuk menafsirkan hasil model dan mengidentifikasi variabel yang paling memengaruhi prediksi.

Pendekatan ini menekankan pentingnya transparansi dan interpretabilitas dalam model pembelajaran mesin yang diterapkan di bidang kesehatan.

(Damayanti, 2025) juga meneliti integrasi *Deep Neural Network* (DNN) dengan Explainable AI melalui penelitian berjudul Model Deteksi Penyakit Jantung Koroner dengan *Principal Component Analysis dan Explainable AI* untuk Interpretabilitas. Penelitian ini menggunakan SHAP dan LIME untuk menjelaskan peran fitur utama hasil reduksi PCA dalam proses klasifikasi. Hasil penelitian menunjukkan bahwa kombinasi DNN dan SHAP dapat meningkatkan pemahaman terhadap perilaku model serta memberikan dasar bagi pengambilan keputusan medis yang lebih terpercaya.

Secara keseluruhan, enam penelitian tersebut menunjukkan perkembangan signifikan dalam penerapan Neural Network dan Explainable AI pada bidang prediksi penyakit jantung. Penelitian berbasis Neural Network menyoroti efektivitas model dalam mengenali pola kompleks data medis, sedangkan penelitian yang mengimplementasikan SHAP menambahkan nilai interpretabilitas yang tinggi terhadap hasil prediksi. Penelitian ini menjadi pijakan penting bagi pengembangan sistem prediksi penyakit jantung yang tidak hanya akurat, tetapi juga transparan dan dapat dipercaya oleh tenaga medis.

2.2 Penyakit Jantung

Penyakit jantung merupakan gangguan pada sistem *kardiovaskular* yang memengaruhi kemampuan jantung dalam memompa darah ke seluruh tubuh. Dalam konteks penelitian ini, penyakit jantung yang dimaksud secara khusus merujuk pada penyakit jantung koroner (*Coronary Artery Disease*), yaitu kondisi ketika aliran

darah menuju otot jantung berkurang akibat penyempitan atau penyumbatan arteri koroner. Penyumbatan tersebut umumnya disebabkan oleh penumpukan plak kolesterol pada dinding pembuluh darah (*atherosclerosis*), sehingga suplai oksigen ke jaringan jantung menjadi terganggu.

Menurut World Health Organization, penyakit jantung koroner merupakan penyebab utama kematian di dunia dengan jumlah kasus yang terus meningkat setiap tahunnya. Kondisi ini berkembang secara bertahap dan sering kali tidak menunjukkan gejala pada tahap awal, sehingga banyak pasien baru terdiagnosis ketika penyakit sudah memasuki fase yang lebih serius. Gejala umum yang muncul meliputi nyeri dada (*angina*), sesak napas, kelelahan, serta gangguan irama jantung akibat berkurangnya aliran darah ke otot jantung.

Berbagai faktor risiko medis berperan penting dalam timbulnya penyakit jantung koroner dan tercermin dalam atribut data yang digunakan pada penelitian ini. Faktor usia (*age*) berhubungan langsung dengan peningkatan risiko, di mana semakin tua seseorang maka elastisitas pembuluh darah cenderung menurun. Jenis kelamin (*sex*) juga memengaruhi tingkat risiko, dengan laki-laki umumnya memiliki kemungkinan lebih tinggi mengalami penyakit jantung koroner pada usia tertentu dibandingkan Perempuan (Roth et al., 2020). Indikator klinis lain yang berkaitan dengan kesehatan *kardiovaskular* meliputi tekanan darah saat istirahat (*restbps*), kadar kolesterol serum (*chol*), serta gula darah puasa (*fbg*) (Kaptoge et al., 2019).

Selain itu, terdapat indikator medis yang secara langsung berkaitan dengan evaluasi fungsi jantung, seperti hasil *elektrokardiografi* (*restecg*), detak jantung

maksimum yang dicapai (*thalach*), depresi segmen ST akibat aktivitas fisik (*oldpeak*), serta kemiringan segmen ST (*slope*). Jumlah pembuluh darah utama yang terdeteksi melalui *fluoroskopi* (*ca*) serta kondisi *thalassemia* (*thal*) juga menjadi parameter penting dalam mendeteksi kemungkinan penyempitan arteri koroner. Gejala klinis seperti nyeri dada (*cp*) dan angina akibat aktivitas fisik (*exang*) sering menjadi indikator awal adanya gangguan aliran darah menuju jantung (Rasmy et al., 2021).

Dengan mempertimbangkan berbagai faktor risiko tersebut, deteksi dini penyakit jantung koroner menjadi sangat krusial dalam upaya pencegahan dan penanganan. Diagnosis yang lebih cepat memungkinkan pasien memperoleh intervensi medis maupun perubahan gaya hidup sebelum kondisi berkembang menjadi serangan jantung. Namun, metode diagnosis konvensional sering menghadapi keterbatasan dalam hal waktu, kompleksitas analisis data medis, serta potensi kesalahan manusia. Oleh karena itu, pemanfaatan teknologi berbasis kecerdasan buatan menjadi relevan karena mampu menganalisis pola data medis yang kompleks secara lebih efisien dan akurat. Hal ini penting terutama di negara berkembang seperti Indonesia yang menghadapi beban tinggi penyakit kardiovaskular sekaligus keterbatasan fasilitas kesehatan. Dengan demikian, penelitian pengembangan model prediksi risiko penyakit jantung koroner berbasis AI memiliki urgensi tinggi dalam mendukung peningkatan layanan kesehatan dan menekan angka mortalitas akibat penyakit jantung.

2.3 Artificial Intelligence dan Machine Learning

Artificial Intelligence (AI) merupakan cabang ilmu komputer yang memungkinkan sistem meniru kemampuan manusia dalam belajar, berpikir, dan mengambil keputusan. Salah satu cabang utamanya adalah *Machine Learning* (ML), yang memungkinkan komputer mengenali pola dari data tanpa harus diprogram secara eksplisit. Dalam bidang kesehatan, AI dan ML banyak dimanfaatkan untuk diagnosis penyakit, prediksi risiko kesehatan, analisis citra medis, hingga rekomendasi perawatan yang lebih tepat (Rajpurkar et al., 2022). Keunggulannya terletak pada kemampuan menganalisis data medis dalam jumlah besar secara cepat dan akurat, sehingga mampu membantu tenaga medis dalam pengambilan keputusan klinis.

Selain itu, penerapan AI juga memberi dampak praktis berupa peningkatan efisiensi layanan, pengurangan biaya pemeriksaan, serta perluasan akses diagnosis dini, terutama di wilayah dengan keterbatasan tenaga medis (Chowdhury et al., 2024)(Serrano et al., 2024) Salah satu algoritma ML yang paling relevan untuk prediksi penyakit jantung adalah *Neural Network*, karena kemampuannya mempelajari pola non-linear yang kompleks dari atribut medis yang beragam dan saling berhubungan (Rasmy et al., 2021).

2.4 Neural Network

Neural Network merupakan salah satu algoritma dalam *Machine Learning* yang tersusun atas neuron buatan yang terbagi ke dalam tiga lapisan utama, yaitu lapisan input, hidden layer, dan lapisan output. Arsitektur ini memiliki berbagai

varian, antara lain *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN), serta *Multi-Layer Perceptron* (MLP).

Dalam penelitian ini digunakan MLP, yaitu bentuk *feedforward neural network* yang banyak diaplikasikan untuk prediksi berbasis data tabular, termasuk data medis. Struktur MLP terdiri atas lapisan input, satu atau lebih hidden layer, dan lapisan output yang saling terhubung melalui bobot (weights) dan bias. Setiap neuron melakukan transformasi linier yang kemudian dilewatkan ke fungsi aktivasi non-linear, sehingga jaringan mampu mempelajari pola kompleks antar variable (Alsawaf et al., 2024).

Keunggulan utama MLP terletak pada kemampuannya mengenali hubungan non-linear yang sulit ditangkap oleh algoritma klasik, sehingga sangat relevan digunakan untuk prediksi penyakit jantung dengan mempertimbangkan atribut klinis seperti usia, tekanan darah, kolesterol, maupun hasil elektrokardiografi (Yuda Syahidin et al., 2022). Namun, meskipun efektif, MLP kerap dipandang sebagai black box karena mekanisme pengambilan keputusannya sulit dipahami. Oleh sebab itu, penelitian ini mengintegrasikan metode *Explainable AI* (SHAP) agar hasil prediksi lebih transparan dan mudah diinterpretasikan (Lundberg et al., 2021).

2.4.1 Arsitektur Multi-Layer Perceptron

Arsitektur *Multi-Layer Perceptron* dalam penelitian ini didasarkan pada model jaringan saraf feedforward yang terdiri dari tiga lapisan utama, yaitu input layer, hidden layer, dan output layer.

1. Input layer berfungsi menerima data medis pasien yang terdiri dari sejumlah atribut, seperti usia, jenis kelamin, tekanan darah, kolesterol,


gula darah puasa, hasil elektrokardiografi, serta atribut klinis lainnya yang terdapat pada dataset penyakit jantung. Setiap atribut direpresentasikan sebagai node dalam lapisan input.

2. Hidden layer merupakan inti dari proses pembelajaran, di mana setiap neuron akan mengolah input dengan bobot tertentu dan fungsi aktivasi. Pada penelitian ini digunakan fungsi aktivasi non-linear, seperti ReLU (*Rectified Linear Unit*), untuk membantu jaringan mempelajari hubungan kompleks antar variabel. Jumlah neuron pada lapisan tersembunyi ditentukan melalui proses eksperimen agar mencapai keseimbangan antara akurasi dan kompleksitas model.
3. Output layer menghasilkan prediksi berupa probabilitas apakah pasien termasuk kategori berisiko penyakit jantung atau tidak. Lapisan ini umumnya menggunakan fungsi aktivasi sigmoid untuk menghasilkan nilai antara 0 dan 1, sehingga dapat dipetakan langsung ke label target biner (0 = tidak berisiko, 1 = berisiko).

Secara matematis, output model dapat dirumuskan sebagai :

$$Z^{[l]} = W^{[l]}X + b^{[l]} \quad (2.1)$$

dimana x_i adalah input, w_i bobot, b bias, dan f fungsi aktivasi. Proses pelatihan dilakukan dengan algoritma *backpropagation* menggunakan optimizer adam, yang bertujuan meminimalkan loss function. Gambaran arsitektur MLP dalam penelitian ini dapat divisualisasikan dalam bentuk diagram struktur jaringan Gambar 2.1.



Gambar 2.1 Arsitektur Model MLP

Dengan struktur ini, model mampu mengolah data medis yang kompleks secara simultan, sehingga diharapkan dapat menghasilkan prediksi yang lebih akurat dibandingkan metode konvensional.

2.4.2 Fungsi Aktivasi

Fungsi aktivasi merupakan komponen penting dalam *Neural Network* yang berfungsi memperkenalkan sifat non-linear pada model. Tanpa fungsi aktivasi, jaringan saraf hanya menghasilkan transformasi linear sehingga tidak mampu mempelajari hubungan kompleks antar fitur. Fungsi aktivasi menentukan bagaimana sinyal yang telah melalui transformasi linier diteruskan ke lapisan berikutnya.

Dalam penelitian ini digunakan beberapa fungsi aktivasi yang diuji melalui proses eksperimen, yaitu *Sigmoid*, *Tanh*, *ReLU*, dan *Leaky ReLU*, untuk menganalisis pengaruhnya terhadap performa model klasifikasi penyakit jantung.

1. Fungsi Aktivasi Sigmoid

Fungsi sigmoid merupakan fungsi aktivasi yang memetakan nilai input ke dalam rentang probabilitas antara 0 hingga 1. Fungsi ini umum digunakan pada lapisan output untuk permasalahan klasifikasi biner karena menghasilkan interpretasi probabilistik.

$$\hat{y} = \sigma(Z) = \frac{1}{1 + e^{-Z}} \quad (2.2)$$

Kelebihan fungsi sigmoid adalah kemampuannya menghasilkan nilai probabilitas yang mudah diinterpretasikan. Namun, fungsi ini memiliki kelemahan berupa masalah vanishing gradient ketika nilai input sangat besar atau sangat kecil.

2. Fungsi Aktivasi Tanh

Fungsi *Hyperbolic Tangent* (Tanh) merupakan pengembangan dari sigmoid yang menghasilkan keluaran pada rentang -1 hingga 1 .

$$f(x) = \tanh(x) \quad (2.3)$$

Dibandingkan sigmoid, fungsi tanh memiliki distribusi keluaran yang berpusat pada nol sehingga proses pembelajaran dapat berlangsung lebih stabil. Fungsi ini sering digunakan pada hidden layer untuk meningkatkan konvergensi model.

3. Fungsi Aktivasi ReLU

Rectified Linear Unit (ReLU) merupakan fungsi aktivasi yang paling umum digunakan pada jaringan saraf modern karena sederhana dan efisien secara komputasi.

$$A^{[l]} = \text{ReLU}(Z^{[l]}) = \max(0, Z^{[l]}) \quad (2.4)$$

ReLU hanya mengaktifkan neuron ketika nilai input bernilai positif dan menghasilkan nol untuk nilai negatif. Hal ini membantu mengurangi permasalahan vanishing gradient serta mempercepat proses pelatihan jaringan.

4. Fungsi Aktivasi Leaky ReLU

Leaky ReLU merupakan pengembangan dari ReLU yang bertujuan mengatasi permasalahan dead neuron, yaitu kondisi ketika neuron berhenti belajar akibat nilai keluaran selalu nol.

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha x, & x \leq 0 \end{cases} \quad (2.5)$$

di mana α merupakan konstanta kecil (biasanya 0.01) yang memungkinkan gradien tetap mengalir pada nilai negatif. Dengan penggunaan beberapa fungsi aktivasi tersebut, penelitian ini bertujuan mengevaluasi pengaruh karakteristik non-linear yang berbeda terhadap performa model Multi-Layer Perceptron dalam memprediksi risiko penyakit jantung.

2.5 Ekplainable AI dan SHAP

Meskipun Neural Network memiliki kemampuan yang sangat baik dalam mempelajari pola kompleks dan menghasilkan prediksi dengan tingkat akurasi tinggi, model ini sering dikategorikan sebagai *black box*. Hal ini disebabkan karena proses pengambilan keputusan di dalam jaringan saraf berlangsung melalui transformasi matematis yang kompleks sehingga sulit dipahami secara langsung oleh manusia. Dalam konteks bidang medis, keterbatasan interpretasi tersebut menjadi tantangan utama, karena tenaga medis tidak hanya membutuhkan hasil prediksi, tetapi juga alasan yang mendasari keputusan model. Oleh karena itu,

diperlukan pendekatan yang mampu menjelaskan mekanisme prediksi model secara transparan tanpa mengurangi performa akurasi, yaitu melalui konsep *Explainable Artificial Intelligence (XAI)*.

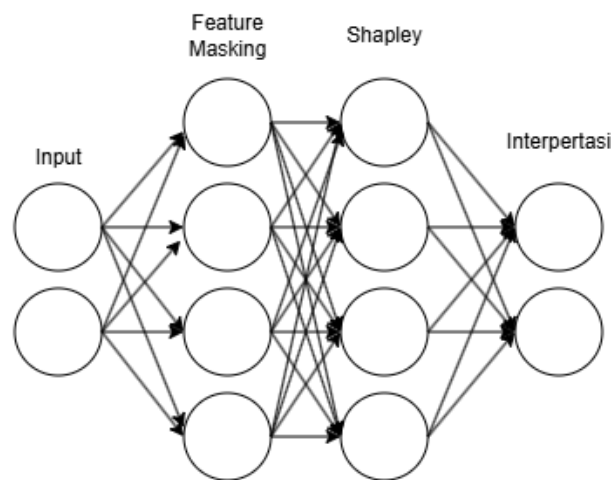
Di Indonesia juga telah terdapat penelitian yang menggabungkan pendekatan XAI untuk memperjelas keputusan model prediksi. Sebagai contoh, (Permana et al., 2024) melakukan penelitian klasifikasi status rujukan pasien poliklinik berbasis Random Forest dengan *interpretabilitas* menggunakan SHAP. Penelitian tersebut menunjukkan bahwa fitur medis seperti usia, tanda vital, dan status pasien memiliki kontribusi berbeda dalam menentukan keputusan rujukan pasien. Hasil penelitian menunjukkan performa model yang baik dengan akurasi sebesar 94,59% dan nilai AUC sebesar 0,91, meskipun nilai precision pada kelas dirujuk relatif rendah akibat ketidakseimbangan data.

Salah satu metode yang banyak digunakan dalam XAI adalah SHAP (*Shapley Additive exPlanations*). SHAP merupakan teknik yang mengukur kontribusi masing-masing fitur terhadap output model berdasarkan teori nilai Shapley dari game theory. Dengan SHAP, setiap atribut medis seperti usia, tekanan darah, atau kadar kolesterol dapat diberikan skor kontribusi yang menunjukkan seberapa besar pengaruhnya terhadap prediksi risiko penyakit jantung.

Keunggulan metode SHAP terletak pada kemampuannya memberikan interpretasi yang konsisten, baik pada tingkat global (keseluruhan model) maupun lokal (kasus individu). Misalnya, penelitian menunjukkan bahwa secara global usia menjadi faktor dominan, tetapi pada kasus individu fitur lain dapat memberikan pengaruh yang lebih signifikan. Dengan demikian, penerapan XAI melalui metode

SHAP mampu menggabungkan keunggulan model prediktif yang akurat dengan transparansi yang dibutuhkan dalam bidang medis.

Untuk memberikan gambaran yang lebih jelas mengenai mekanisme kerja SHAP dalam menjelaskan prediksi model, alur proses interpretasi SHAP divisualisasikan seperti yang ditunjukkan pada Gambar 2.2.



Gambar 2.2 Arsitektur SHAP

Gambar 2.2 menunjukkan proses interpretasi SHAP yang dimulai dari data input yang diproses oleh model prediksi, kemudian dilakukan evaluasi kontribusi fitur melalui mekanisme feature masking. Setiap fitur dianalisis berdasarkan perubahan output model ketika fitur tersebut digunakan maupun dihilangkan. Hasil proses ini menghasilkan nilai Shapley yang merepresentasikan kontribusi masing-masing fitur terhadap hasil prediksi, baik pada tingkat global maupun lokal, sehingga keputusan model menjadi lebih transparan dan mudah dipahami.

2.5.1 Model Interpretabilitas dengan SHAP

SHAP (*Shapley Additive exPlanations*) merupakan metode interpretabilitas model yang didasarkan pada teori nilai Shapley dalam game theory. Dalam pendekatan ini, setiap fitur input dipandang sebagai “pemain” dalam suatu permainan kooperatif, sedangkan output prediksi model dianggap sebagai hasil akhir permainan tersebut. Tujuan utama SHAP adalah mengukur kontribusi masing-masing fitur terhadap hasil prediksi secara adil dan konsisten.

Dalam konteks model prediksi penyakit jantung, atribut seperti usia, tekanan darah, kadar kolesterol, dan variabel klinis lainnya berperan sebagai faktor yang secara bersama-sama memengaruhi keputusan model dalam menentukan tingkat risiko pasien. Oleh karena itu, diperlukan suatu mekanisme untuk mengetahui seberapa besar pengaruh masing-masing fitur terhadap output model.

Proses interpretasi SHAP dilakukan melalui mekanisme feature masking, yaitu dengan menghilangkan suatu fitur dari kombinasi fitur lainnya untuk mengamati perubahan pada output model. Kontribusi suatu fitur i terhadap subset fitur S dinyatakan sebagai perubahan output model yang disebut sebagai marginal contribution, yang dirumuskan sebagai berikut:

$$\Delta f(i, S) = f(S \cup i) - f(S) \quad (2.6)$$

Keterangan :

S = subset fitur tanpa i

$f(S)$ = output model hanya dengan subset fitur S

$f(S \cup i)$ = output model ketika fitur i ditambahkan

Nilai marginal contribution tersebut menunjukkan besarnya perubahan prediksi akibat keberadaan fitur i pada kombinasi fitur tertentu. Semakin besar perubahan

output yang dihasilkan, maka semakin besar pula kontribusi fitur tersebut terhadap keputusan model.

2.5.2 Perhitungan Shapley Value

Untuk memperoleh kontribusi akhir suatu fitur secara menyeluruh, perhitungan tidak hanya dilakukan pada satu kombinasi subset fitur, melainkan pada seluruh kemungkinan kombinasi subset yang mungkin terbentuk. Setiap nilai marginal contribution dihitung dan dirata-ratakan dengan pembobotan tertentu agar mencerminkan kontribusi yang adil.

Kontribusi akhir tersebut dikenal sebagai Shapley Value, yang dirumuskan secara matematis sebagai berikut:

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f(S \cup \{i\}) - f(S)] \quad (2.7)$$

Keterangan:

- F = himpunan semua fitur,
- S = subset dari fitur selain i ,
- $f(S)$ = output model berdasarkan subset fitur S ,
- ϕ_i = nilai kontribusi fitur i .

Faktor pembobotan dalam persamaan tersebut memastikan bahwa setiap kemungkinan urutan kemunculan fitur dalam permainan kooperatif dipertimbangkan secara proporsional. Dengan demikian, nilai Shapley memenuhi beberapa sifat penting, yaitu:

- a) Efficiency, yaitu jumlah seluruh nilai Shapley sama dengan selisih antara output prediksi keterjelasansar (baseline prediction).
- b) Symmetry, yaitu fitur yang memiliki pengaruh identik akan memperoleh nilai kontribusi yang sama.

- c) Dummy, yaitu fitur yang tidak memberikan perubahan output akan memiliki nilai kontribusi nol.
- d) Additivity, yaitu kontribusi pada model gabungan sama dengan penjumlahan kontribusi pada masing-masing model.

Melalui formulasi tersebut, SHAP mampu memberikan interpretasi yang bersifat aditif, konsisten, dan memiliki dasar matematis yang kuat. Oleh karena itu, penerapan SHAP pada model Neural Network tidak hanya mempertahankan performa prediksi yang tinggi, tetapi juga meningkatkan transparansi dan keterjelasan alasan di balik setiap keputusan model.

2.6 Evaluasi model

Evaluasi model merupakan tahap penting dalam proses pembangunan sistem berbasis *Machine Learning* maupun *Deep Learning*. Tujuannya adalah untuk mengukur sejauh mana model mampu memberikan prediksi yang akurat dan dapat diandalkan ketika dihadapkan pada data yang belum pernah dilihat sebelumnya. Dalam bidang kesehatan, tahap evaluasi menjadi krusial karena kesalahan prediksi dapat berdampak langsung pada pengambilan keputusan medis yang memengaruhi keselamatan pasien. Beberapa metrik evaluasi yang umum digunakan antara lain:

1. Akurasi (*Accuracy*)

Mengukur persentase prediksi yang benar dibandingkan dengan keseluruhan data uji. Namun, akurasi saja tidak cukup ketika data tidak seimbang (*imbalanced dataset*).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.8)$$

2. Presisi (*Precision*)

Rasio antara jumlah prediksi positif yang benar dengan seluruh prediksi positif. Presisi tinggi penting untuk mengurangi jumlah false positive.

$$Precision = \frac{TP}{TP + FP} \quad (2.9)$$

3. Recall (*Sensitivity/True Positive Rate*)

Rasio antara jumlah prediksi positif yang benar dengan seluruh data positif sebenarnya. Recall tinggi penting untuk memastikan kasus penyakit tidak terlewat (minim false negative).

$$Recall = \frac{TP}{TP + FN} \quad (2.10)$$

4. F1-Score

Merupakan harmonic mean antara precision dan recall. Cocok digunakan ketika terdapat ketidakseimbangan data.

$$F1 = 2 \times \frac{precision \times Recall}{precision + Recall} \quad (2.11)$$

5. Area Under the Curve – Receiver Operating Characteristic (AUC-ROC)

Menggambarkan kemampuan model dalam membedakan antara kelas positif dan negatif. Nilai AUC mendekati 1 menunjukkan performa model yang sangat baik.

Dalam penelitian terkait prediksi penyakit jantung, penggunaan metrik evaluasi seperti *precision*, *recall*, *F1-score*, dan *AUC* lebih disarankan daripada

hanya bergantung pada akurasi, karena kesalahan klasifikasi dapat berakibat serius terhadap penanganan pasien (Rajpurkar et al., 2022).

BAB III


METODOLOGI PENELITIAN

3.1 Pendahuluan

Metodologi penelitian merupakan tahapan yang digunakan untuk mencapai tujuan penelitian secara sistematis. Pada penelitian ini, pendekatan yang digunakan adalah eksperimen kuantitatif dengan memanfaatkan dataset penyakit jantung dari Kaggle. Proses penelitian dilakukan melalui serangkaian tahap mulai dari persiapan data, pembagian dataset, *preprocessing*, perancangan model *Neural Network*, pelatihan dan validasi model, evaluasi hingga interpretasi hasil menggunakan SHAP. Dengan rancangan ini, penelitian diharapkan mampu menghasilkan model prediksi penyakit jantung yang akurat sekaligus dapat dijelaskan secara transparan melalui metode *Explainable AI*.

3.2 Desain Penelitian

Desain penelitian ini disusun untuk memberikan gambaran sistematis mengenai tahapan pembangunan model prediksi penyakit jantung berbasis *Neural Network* dengan pendekatan *Explainable AI* (SHAP). Tujuan utama dari penelitian ini adalah menghasilkan model yang tidak hanya memiliki performa tinggi dalam melakukan klasifikasi, tetapi juga mampu memberikan interpretasi yang jelas mengenai kontribusi setiap fitur terhadap hasil prediksi, sehingga hasil yang diperoleh lebih transparan dan dapat dipahami. Alur penelitian yang di tempuh dalam penelitian ini di visualisasikan dalam bentuk diagram sebagaimana ditunjukkan pada Gambar 3.1.



Gambar 3.1 Diagram Desain Penelitian

Penelitian ini diawali dengan penggunaan Heart Disease Predictions Dataset yang berisi 303 data pasien dengan 14 atribut input dan 1 atribut target. Dataset terlebih dahulu melalui tahap *preprocessing*, meliputi pembersihan data, normalisasi variabel numerik, serta encoding variabel kategorikal agar siap digunakan pada model. Setelah *preprocessing*, data dibagi menjadi training set (80%) dan testing set (20%).

Model yang digunakan adalah *Multi-Layer Perceptron* (MLP) dengan pengaturan jumlah layer, neuron, fungsi aktivasi, serta optimizer dan loss function. Proses pelatihan dilengkapi dengan teknik *dropout* dan *early stopping* untuk mencegah *overfitting*.

Tahap berikutnya adalah evaluasi model menggunakan metrik klasifikasi, guna mengukur kinerja prediksi secara menyeluruh. Setelah model terbukti memiliki performa yang baik, dilakukan interpretasi menggunakan SHAP untuk menjelaskan kontribusi fitur terhadap hasil prediksi, baik pada tingkat global maupun lokal.

3.3 Persiapan Data

Dataset yang digunakan dalam penelitian ini adalah dataset penyakit jantung (Heart Disease Dataset) yang berisi data rekam medis pasien dengan berbagai atribut klinis yang relevan terhadap kondisi kesehatan jantung. Dataset ini banyak digunakan sebagai benchmark dalam penelitian machine learning di bidang kesehatan karena memiliki variabel yang cukup lengkap untuk proses klasifikasi.

Secara umum, dataset terdiri dari 303 data pasien dengan 14 atribut utama. Atribut tersebut meliputi data demografis, hasil pemeriksaan klinis, serta variabel target yang menunjukkan apakah pasien menderita penyakit jantung (target = 1) atau tidak (target = 0). Sebagai ilustrasi, berikut contoh dari dataset yang digunakan:

Tabel 3.1 Struktur Dataset Penyakit Jantung

index	age	sex	cp	trestbps	chol	fbs	restecg	thalach	exang	oldpeak	slope	ca	thal	target
1	63	1	3	145	233	1	0	150	0	2.3	0	0	1	1
2	37	1	2	130	250	0	1	187	0	3.5	0	0	2	1
3	41	0	1	130	204	0	0	172	0	1.4	2	0	2	1
...
50	57	0	0	120	354	0	1	163	1	0.6	2	0	2	1
51	57	1	0	140	192	0	1	148	0	0.4	1	0	1	1
52	56	0	1	140	294	0	0	153	0	1.3	1	0	2	1
...
151	52	1	2	172	199	1	1	162	0	0.5	2	0	3	1
152	57	1	2	150	168	0	1	174	0	1.6	2	0	2	1
153	54	1	0	140	239	0	1	160	0	1.2	2	0	2	1
...
300	49	1	1	130	266	0	1	171	0	0.6	2	0	2	1
301	58	0	3	150	283	1	0	162	0	1	2	0	2	1
302	50	0	2	120	219	0	1	158	0	1.6	1	0	2	1
303	38	1	2	138	175	0	0	173	0	0	0	0	1	0

Adapun atribut-atribut pada dataset dapat dijelaskan sebagai berikut:

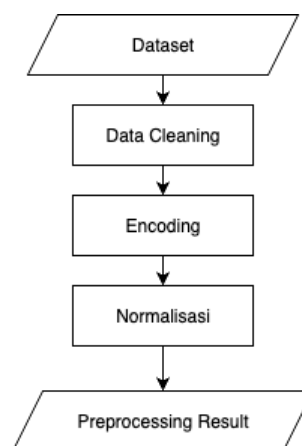
1. age : Usia pasien dalam tahun.
2. sex : Jenis kelamin (0 = perempuan, 1 = laki-laki).
3. cp (*Chest Pain Type*) : Tipe nyeri dada (0 = *Typical Angina*, 1 = *Atypical Angina*, 2 = *Non-Anginal*, 3 = *Asymptomatic*).
4. trestbps (*Resting Blood Pressure*) : Tekanan darah saat istirahat (mmHg).
5. chol (*Serum Cholesterol*) : Kadar kolesterol dalam darah (mg/dl).
6. fbs (*Fasting Blood Sugar*) : Kadar gula darah puasa (>120 mg/dl: 1, ≤120 mg/dl:0).
7. restecg (*Resting ECG Results*) : Hasil elektrokardiografi saat istirahat (0–2).
8. thalach (*Maximum Heart Rate Achieved*) : Detak jantung maksimum yang dicapai.
9. exang (*Exercise Induced Angina*) : Apakah pasien mengalami angina saat olahraga (1 = ya, 0 = tidak).
10. oldpeak : Depresi segmen ST relatif terhadap kondisi istirahat.
11. slope (*Slope of ST Segment*) : Kemiringan segmen ST saat puncak olahraga (0 = up, 1 = flat, 2 = down).
12. ca : Jumlah pembuluh darah besar (0–3) yang terlihat melalui fluoroskopi.
13. thal : *Status thalassemia* (1 = normal, 2 = fixed defect, 3 = reversible defect).
14. target : Label keluaran (1 = pasien menderita penyakit jantung, 0 = tidak).

Dari tabel di atas terlihat bahwa setiap pasien memiliki data numerik maupun kategorikal yang menggambarkan kondisi klinis. Data inilah yang

kemudian digunakan pada tahap preprocessing sebelum masuk ke pemodelan neural network.

3.4 Preprocessing Data

Dataset yang digunakan dalam penelitian ini adalah Heart Disease Predictions Dataset yang berisi 303 data pasien dengan 14 atribut klinis serta 1 atribut target berupa status penyakit jantung (1 = berisiko, 0 = tidak berisiko). Proses preprocessing ini meliputi pembersihan data, encoding variabel kategorikal, serta normalisasi variabel numerik agar siap diolah oleh *Neural Network*. Ilustrasi umum proses preprocessing ditunjukkan pada Gambar 3.2.



Gambar 3.2 Diagram Preprocessing

1. Pembersihan Data (Data Cleaning)

Mengecek data hilang (*missing values*), duplikat, atau data tidak konsisten. Jika ada nilai kosong, dilakukan penghapusan atau imputasi agar kualitas dataset tetap terjaga. Pada dataset ini tidak ditemukan adanya nilai kosong, sehingga kualitas data relatif baik. Dengan demikian, dataset dapat langsung digunakan dan diproses lebih lanjut ke tahap berikutnya

2. Encoding Variabel Kategorikal

Fitur kategorikal seperti sex, cp, restecg, exang, slope, ca, dan thal dikonversi ke bentuk numerik menggunakan *One-Hot Encoding* atau Label Encoding, sehingga dapat diproses oleh *Neural Network*. Contoh Hasil encoding sederhana untuk fitur cp (Chest Pain Type):

- a. Cp_0 → Typical Angina
- b. Cp_1 → Atypical Angina
- c. Cp_2 → Non-Anginal
- d. Cp_3 → Asymptomatic

3. Normalisasi Data

Untuk menyamakan skala antar fitur numerik seperti age, chol, dan trestbps, digunakan teknik Min-Max Scaling dengan rentang [0,1]. Teknik ini bertujuan untuk mencegah model menjadi bias terhadap fitur yang memiliki rentang nilai lebih besar (Sza Amulya Larasati et al., 2023).

Rumus tersebut bekerja dengan cara mengurangi nilai asli x dengan nilai minimum (x_{min}) untuk menggeser skala ke titik awal 0, lalu membaginya dengan rentang nilai ($x_{max} - x_{min}$) sehingga dipetakan ke dalam interval [0,1]. Dengan demikian, nilai terkecil pada fitur akan menjadi 0, nilai terbesar akan menjadi 1, dan nilai lainnya akan berada di antara keduanya sesuai proporsinya. Hasil penerapan Min-Max Scaling dan encoding pada variabel kategorikal ditunjukkan pada tabel berikut:

Tabel 3.2 Contoh Dataset setelah melalui proses encoding dan normalisasi

index	age	trestbps	chol	thalach	oldpeak	target	sex_0	sex_1	restecg_0	restecg_1	restecg_2	exang_0	exang_1
1	0.708333	0.481132	0.244292	0.603053	0.370968	1	0	1	1	0	0	1	0
2	0.166667	0.339623	0.283105	0.885496	0.564516	1	0	1	0	1	0	1	0
3	0.25	0.339623	0.178082	0.770992	0.225806	1	1	0	1	0	0	1	0
...
50	0.583333	0.245283	0.520548	0.70229	0.096774	1	1	0	0	1	0	0	1
51	0.583333	0.433962	0.150685	0.587786	0.064516	1	0	1	0	1	0	1	0
52	0.5625	0.433962	0.383562	0.625954	0.209677	1	1	0	1	0	0	1	0
...
151	0.479167	0.735849	0.166667	0.694656	0.080645	1	0	1	0	1	0	1	0
152	0.583333	0.528302	0.09589	0.78626	0.258065	1	0	1	0	1	0	1	0
153	0.520833	0.433962	0.257991	0.679389	0.193548	1	0	1	0	1	0	1	0
...
300	0.416667	0.339623	0.319635	0.763359	0.096774	1	0	1	0	1	0	1	0
301	0.729167	0.150943	0.194064	0.557252	0.290323	1	0	1	1	0	0	0	1
302	0.604167	0.528302	0.358447	0.694656	0.16129	1	1	0	1	0	0	1	0
303	0.4375	0.245283	0.212329	0.664122	0.258065	1	1	0	0	1	0	1	0

Pada Tabel 3.2 diperlihatkan Contoh dataset setelah melalui proses encoding dan normalisasi. Nilai numerik seperti usia 63 tahun dinormalisasi menjadi 0,708 pada kolom age, sedangkan variabel kategorikal seperti jenis kelamin yang semula bernilai 1 diubah menjadi representasi biner pada kolom sex_0 dan sex_1. Perubahan ini membuat semua fitur berada pada skala seragam dalam rentang 0–1 dan variabel kategorikal terpisah ke dalam kolom khusus, sehingga dataset yang semula heterogen menjadi lebih terstruktur, terstandarisasi, dan siap diproses oleh model *Neural Network*.

3.5 Pembagian Dataset

Setelah tahap preprocessing, data kemudian dibagi menjadi dua bagian, yaitu training set dan testing set. Pembagian dataset ini bertujuan agar model dapat dilatih menggunakan sebagian besar data, sementara sebagian lainnya digunakan untuk menguji kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya.

Pada penelitian ini, pembagian dataset dilakukan dengan proporsi 80% sebagai training set dan 20% sebagai *testing set*. Training set digunakan untuk melatih model Neural Network sehingga dapat mempelajari pola dan hubungan antar fitur terhadap label target. Sementara itu, *testing set* digunakan untuk mengevaluasi performa model setelah proses pelatihan selesai. Secara matematis, jumlah data training dan testing ditentukan dengan rumus:

$$N_{train} = (1 - \alpha) \times N, N_{test} = \alpha \times N \quad (3.1)$$


dengan N adalah jumlah total data, dan α adalah proporsi test (0.2). Pada dataset UCI Heart Disease yang berjumlah 303 data, diperoleh:

$$N_{train} = (1 - 0.2) \times 303 = 242, N_{test} = 0.2 \times 303 = 61 \quad (3.2)$$

Metode train-test split sederhana dipilih dalam penelitian ini karena jumlah dataset relatif kecil (303 data) dan pendekatan ini sudah umum digunakan dalam penelitian terdahulu yang menggunakan dataset Heart Disease.

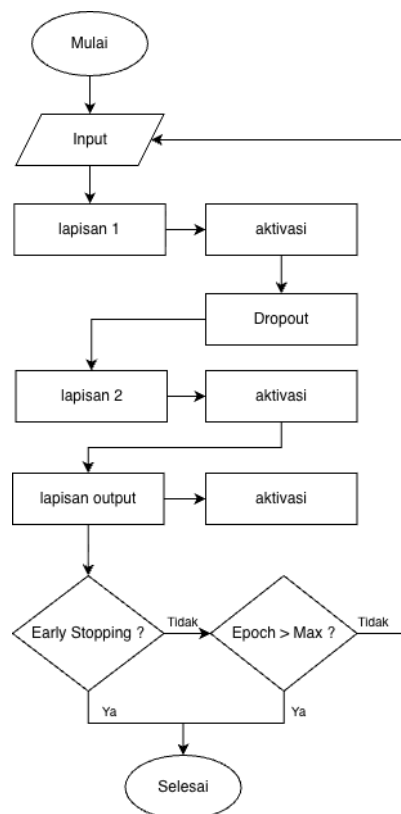
3.6 Perancangan Model *Multi-Layer Perceptron* (MLP)

Tahap ini bertujuan untuk merancang arsitektur jaringan *Multi-Layer Perceptron* (MLP) yang disesuaikan dengan karakteristik Heart Disease Dataset. Setelah melalui tahap preprocessing, yaitu proses encoding variabel kategorikal dan normalisasi fitur numerik, dataset memiliki 31 atribut input serta satu variabel target biner (0 = tidak berisiko, 1 = berisiko). Perancangan arsitektur model dilakukan agar jaringan mampu menangkap pola data secara optimal sekaligus menjaga kemampuan generalisasi sehingga risiko *overfitting* dapat diminimalkan.



Gambar 3.3 Arsitektur Model MLP

Secara umum, arsitektur Multi-Layer Perceptron terdiri atas lapisan input, satu atau lebih hidden layer, serta lapisan output yang saling terhubung melalui bobot dan bias. Setiap neuron pada suatu lapisan menerima sinyal dari neuron pada lapisan sebelumnya, kemudian memprosesnya melalui fungsi aktivasi sebelum diteruskan ke lapisan berikutnya. Struktur dasar jaringan saraf tiruan tersebut dapat divisualisasikan seperti pada Gambar 3.3, yang menggambarkan alur propagasi data dari input menuju output melalui beberapa lapisan neuron yang saling terhubung.



Gambar 3.4 Perancangan Model Multi-Layer Preception

Arsitektur model terdiri atas beberapa lapisan utama. Lapisan pertama adalah input layer, yang memiliki jumlah neuron sesuai dengan jumlah fitur setelah proses preprocessing, yaitu sebanyak 31 neuron. Lapisan ini berfungsi menerima

vektor fitur pasien yang kemudian diteruskan ke lapisan tersembunyi untuk diproses lebih lanjut.

Lapisan berikutnya adalah *hidden layer*, yang berperan sebagai pusat pembelajaran jaringan saraf dalam mengekstraksi pola dari data masukan. Pada penelitian ini, jumlah *hidden layer* serta jumlah neuron pada setiap lapisan tidak ditetapkan secara tunggal, melainkan divariasikan melalui beberapa skenario eksperimen untuk menganalisis pengaruh kompleksitas arsitektur terhadap performa model. Fungsi aktivasi non-linear diterapkan pada *hidden layer* untuk memungkinkan jaringan mempelajari hubungan kompleks antar atribut medis.

Untuk mengurangi risiko *overfitting*, arsitektur model juga memanfaatkan dropout layer yang diterapkan setelah hidden layer. Mekanisme dropout bekerja dengan menonaktifkan sebagian neuron secara acak selama proses pelatihan sehingga model tidak bergantung pada neuron tertentu dan mampu melakukan generalisasi lebih baik terhadap data baru.

Sebagai lapisan terakhir, digunakan output layer yang terdiri dari satu neuron dengan fungsi aktivasi sigmoid. Fungsi sigmoid menghasilkan nilai probabilitas antara 0 dan 1 yang merepresentasikan kemungkinan pasien termasuk dalam kategori berisiko penyakit jantung. Nilai probabilitas yang mendekati 1 menunjukkan risiko penyakit jantung yang lebih tinggi, sedangkan nilai yang mendekati 0 menunjukkan kondisi tidak berisiko.

Jumlah neuron pada *hidden layer*, variasi fungsi aktivasi, serta konfigurasi arsitektur lainnya ditentukan melalui proses eksperimen yang dijelaskan lebih lanjut pada subbab desain eksperimen. Dengan rancangan arsitektur umum tersebut,

model *Multi-Layer Perceptron* diharapkan mampu mempelajari pola hubungan antar atribut klinis secara efektif dan menghasilkan prediksi yang akurat pada data penyakit jantung.

3.7 Training dan Validation Model MLP

Tahap ini merupakan proses pelatihan (training) terhadap model *Multi-Layer Perceptron* yang telah dirancang pada tahap sebelumnya. Proses pelatihan dilakukan dengan menggunakan training set sebesar 80% dari total dataset, sedangkan testing set sebesar 20% digunakan sebagai data validasi untuk mengukur kemampuan generalisasi model. Pemisahan ini bertujuan agar model tidak hanya menghafal pola pada data latih, tetapi juga dapat memberikan performa yang baik pada data baru. Pelatihan dilakukan dengan konfigurasi sebagai berikut:

- a. Epoch: maksimal 100 iterasi pelatihan, sehingga model memiliki kesempatan yang cukup untuk mempelajari pola data.
- b. Batch Size: 32 data per batch, agar proses pembaruan bobot berjalan lebih stabil dan efisien.
- c. Optimizer Adam : menyesuaikan learning rate secara adaptif untuk menjaga kestabilan pelatihan, terutama pada dataset berskala kecil.
- d. Fungsi loss : Binary Cross-Entropy

Untuk mengurangi risiko *overfitting*, diterapkan *Dropout* pada *hidden layer* pertama dan Early Stopping dengan patience 10 epoch, sehingga pelatihan berhenti lebih awal jika tidak ada peningkatan pada data validasi.

Selama proses pelatihan, model secara bertahap menyesuaikan bobotnya menggunakan algoritma backpropagation dengan optimizer adam. Nilai loss dan

akurasi dicatat pada setiap epoch, baik untuk data latih maupun data validasi, untuk memantau perkembangan performa model. Mekanisme ini juga memungkinkan deteksi dini terhadap potensi overfitting.

Pada tahap pelatihan model, kinerja Multi-Layer Perceptron (MLP) akan dievaluasi dengan memantau perubahan nilai loss dan akurasi pada data pelatihan dan data validasi. Secara umum, model dikatakan mampu belajar dengan baik apabila nilai loss mengalami penurunan secara bertahap dan akurasi meningkat seiring bertambahnya jumlah epoch. Evaluasi performa pelatihan ini juga bertujuan untuk mengetahui apakah model mengalami overfitting atau underfitting, sehingga dapat dilakukan penyesuaian parameter bila diperlukan.

3.8 Evaluasi

Evaluasi dilakukan pada data uji (testing set), yaitu data yang tidak pernah digunakan oleh model selama proses pelatihan. Tujuan evaluasi adalah untuk mengukur kemampuan generalisasi model dalam memprediksi data baru. Evaluasi performa model *Multi-Layer Perceptron* ini menggunakan beberapa metrik klasifikasi, yaitu *akurasi*, *presisi*, *recall*, *F1-score*, dan *AUC-ROC*.

1. Akurasi

Mengukur rasio prediksi yang benar (baik positif maupun negatif) terhadap total data uji.

2. Presisi

Mengukur ketepatan prediksi positif yang dihasilkan model, penting untuk meminimalkan false positive.

3. Recall (Sensitivity / True Positive Rate)

Mengukur kemampuan model dalam mendeteksi semua kasus positif sebenarnya, penting untuk mengurangi false negative.

4. F1-Score


Nilai rata-rata harmonik dari presisi dan recall, memberikan gambaran performa seimbang terutama jika distribusi kelas tidak seimbang.

5. AUC (Area Under the Curve)

Menggambarkan kemampuan model secara keseluruhan dalam membedakan antara kelas positif dan negatif. Nilai AUC berkisar antara 0–1, semakin mendekati 1 semakin baik kemampuan diskriminatif model.

3.9 Interpretasi Model Menggunakan SHAP

Tahap interpretasi dengan metode SHAP (*Shapley Additive Explanations*) dilakukan untuk memahami kontribusi masing-masing fitur dalam memengaruhi hasil prediksi yang dihasilkan oleh model *Multi-Layer Perceptron*. Dengan adanya interpretasi ini, sistem prediksi tidak hanya memberikan hasil berupa nilai klasifikasi, tetapi juga menyertakan alasan yang mendasarinya, sehingga hasil dapat lebih transparan dan dipercaya oleh tenaga medis maupun peneliti.



Gambar 3.5 Diagram Interpretasi SHAP

Alur interpretasi SHAP yang ditunjukkan pada Gambar 3.5, yang menggambarkan proses mulai dari input data uji, evaluasi kontribusi fitur dengan mekanisme feature masking, perhitungan nilai Shapley, hingga menghasilkan interpretasi pada level lokal maupun global.

3.9.1 Input Data

Tahap awal interpretasi dilakukan dengan memasukkan data uji yang sudah melalui preprocessing ke dalam model *Multi-Layer Perceptron* terlatih. Output model berupa probabilitas risiko penyakit jantung kemudian menjadi dasar untuk analisis lebih lanjut menggunakan metode SHAP.

3.9.3 Perhitungan Nilai Shapley

Pada tahap ini dilakukan perhitungan nilai SHAP untuk setiap fitur input guna mengetahui kontribusi masing-masing atribut terhadap hasil prediksi model. Perhitungan dilakukan menggunakan model terbaik yang diperoleh dari skenario pengujian sebelumnya. Nilai SHAP menunjukkan apakah suatu fitur memberikan kontribusi positif atau negatif terhadap probabilitas prediksi risiko penyakit jantung.

3.9.4 Visualisasi dan Analisis Interpretasi SHAP

Tahap interpretasi merupakan langkah akhir analisis dengan SHAP, di mana nilai Shapley digunakan untuk menjelaskan kontribusi tiap fitur terhadap hasil prediksi. Proses ini membuat model lebih transparan, karena selain memberikan hasil klasifikasi, juga disertai alasan di balik keputusan sehingga meningkatkan kepercayaan pengguna.

1. Interpretasi Lokal, yang menekankan pada individu tertentu (misalnya satu pasien). Hasil ini menunjukkan fitur mana saja yang paling berpengaruh terhadap prediksi pasien tersebut.
2. Interpretasi Global, yang menekankan pada keseluruhan dataset. Hasil ini menunjukkan fitur-fitur dominan yang secara umum paling memengaruhi model dalam mengambil keputusan.

Dengan adanya interpretasi baik pada level lokal maupun global, SHAP memberikan pemahaman yang lebih mendalam mengenai perilaku model. Hal ini penting untuk mengurangi sifat *black-box* dari *Neural Network*, sekaligus meningkatkan kepercayaan pengguna terhadap hasil prediksi.

3.10 Output

Output penelitian ini mencakup dua hal utama. Pertama, model *Multi-Layer Perceptron* (MLP) akan dikembangkan untuk melakukan prediksi risiko penyakit jantung dengan mengukur performa menggunakan metrik evaluasi seperti akurasi, presisi, recall, F1-score, dan AUC-ROC. Kedua, penelitian ini akan menghasilkan interpretasi model menggunakan metode *Explainable AI* berbasis SHAP, yang menjelaskan kontribusi setiap fitur terhadap hasil prediksi secara global maupun lokal. Dengan demikian, model tidak hanya memberikan hasil prediksi, tetapi juga alasan yang dapat dipertanggungjawabkan secara ilmiah, sehingga lebih transparan dan dapat dipercaya dalam konteks medis.

3.11 Skenario Pengujian

Skenario pengujian disusun untuk memastikan bahwa model yang dibangun tidak hanya memiliki konfigurasi arsitektur yang optimal, tetapi juga memiliki performa prediksi yang baik. Oleh karena itu, pengujian dibagi menjadi dua skenario utama, yaitu skenario eksperimen hyperparameter MLP dan skenario evaluasi performa model MLP terbaik.

Tabel 3.3 Skenario Pengujian

Skenario	Tujuan	Data	Metrik / Metode	Kriteria Keberhasilan
Eksperimen Hyperparameter MLP	Menentukan konfigurasi arsitektur dan fungsi aktivasi terbaik pada model MLP	Data latih (80%) dan data uji (20%)	neuron (16–16, 16–8, 32–16, 32–32, 64–32, 64–64, 128–64) dan fungsi aktivasi (sigmoid, tanh, ReLU, Leaky ReLU), dievaluasi dengan Accuracy, F1-	Diperoleh satu kombinasi arsitektur dan fungsi aktivasi dengan nilai akurasi tertinggi sebagai model terbaik

Skenario	Tujuan	Data	Metrik / Metode	Kriteria Keberhasilan
			Score, AUC-ROC	
Performa Model (MLP)	Mengukur akurasi dan keandalan prediksi	Data uji (20%)	Accuracy, Precision, Recall, F1-Score, AUC-ROC	Akurasi ≥ 0.85
				F1-Score ≥ 0.80
				AUC ≥ 0.85

Berdasarkan Tabel 3.3, pada skenario pertama dilakukan eksperimen hyperparameter pada model Multi-Layer Perceptron (MLP). Eksperimen ini mencakup variasi jumlah neuron pada dua hidden layer, yaitu 16–16, 16–8, 32–16, 32–32, 64–32, 64–64, dan 128–64, serta variasi fungsi aktivasi pada hidden layer, yaitu sigmoid, tanh, ReLU, dan Leaky ReLU. Setiap kombinasi dievaluasi menggunakan metrik akurasi, F1-score, dan AUC-ROC pada data uji. Skenario ini bertujuan untuk memperoleh satu konfigurasi arsitektur dan fungsi aktivasi yang memberikan performa terbaik dan memenuhi batas minimal akurasi, F1-score, dan AUC yang telah ditetapkan.

Pada skenario kedua, pengujian difokuskan pada evaluasi performa model MLP terbaik yang diperoleh dari skenario pertama. Model tersebut diuji menggunakan data uji yang mencakup 20% dari total dataset. Evaluasi dilakukan dengan menggunakan metrik klasifikasi berupa akurasi, presisi, recall, F1-score, dan AUC-ROC. Model dianggap berhasil apabila memenuhi kriteria: akurasi minimal 85%, F1-score minimal 80%, dan AUC minimal 85%. Dengan demikian, hasil pengujian pada skenario ini menunjukkan seberapa andal model dalam memprediksi risiko penyakit jantung secara komprehensif.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah Heart Disease Claveland yang berisi 303 data pasien dengan 14 fitur medis dan 1 label target (0 = tidak berisiko, 1 = berisiko). Fitur-fitur yang digunakan mencakup parameter klinis seperti usia, jenis kelamin, tekanan darah, kolesterol, detak jantung maksimum, tipe nyeri dada, jumlah pembuluh darah yang terlihat, dan indikator medis lainnya yang relevan untuk mendeteksi penyakit jantung. Dataset ini dipilih karena merupakan dataset standar dan banyak digunakan dalam penelitian terkait prediksi penyakit jantung.

4.2 Hasil Preprocessing

Tahap preprocessing dilakukan untuk mempersiapkan dataset sebelum digunakan dalam pelatihan model Neural Network. Dataset yang digunakan berisi 303 data pasien penyakit jantung dengan 14 atribut input dan 1 atribut target. Tahapan preprocessing yang dilakukan meliputi pembersihan data, encoding variabel kategorikal, normalisasi data numerik, dan pembagian dataset menjadi data latih dan data uji.

4.2.1 Data Cleaning

Pada tahap pembersihan data, dilakukan pemeriksaan terhadap kemungkinan adanya data kosong (missing value), data duplikat, dan nilai yang

tidak sesuai. Hasil pengecekan menunjukkan bahwa tidak terdapat data kosong maupun duplikat pada seluruh kolom dataset. Nilai pada masing-masing atribut juga berada dalam rentang yang wajar, seperti usia pasien antara 29 hingga 77 tahun dan kadar kolesterol antara 126 hingga 564 mg/dl.

Jumlah nilai hilang sebelum dibersihkan:		Jumlah nilai hilang setelah dibersihkan:	
age	0	age	0
sex	0	sex	0
cp	0	cp	0
trestbps	0	trestbps	0
chol	0	chol	0
fbs	0	fbs	0
restecg	0	restecg	0
thalach	0	thalach	0
exang	0	exang	0
oldpeak	0	oldpeak	0
slope	0	slope	0
ca	0	ca	0
thal	0	thal	0
target	0	target	0

Gambar 4.1 Haisl Data Setelah Cleaning

Pada gambar 4.1. Karena dataset sudah bersih, maka tidak diperlukan proses penghapusan atau imputasi data. Dataset dinyatakan siap untuk digunakan pada tahap selanjutnya.

4.2.2 Encoding

Tahap berikutnya adalah mengubah variabel kategorikal menjadi bentuk numerik agar dapat diproses oleh model Neural Network. Variabel yang dikonversi antara lain sex, cp, restecg, exang, slope, ca, dan thal. Proses ini dilakukan dengan metode One-Hot Encoding, yaitu memecah setiap kategori menjadi kolom baru yang merepresentasikan nilai biner (0 atau 1). Setelah proses encoding selesai, jumlah kolom pada dataset meningkat dari 14 kolom menjadi 31 kolom.

Sebagai contoh, fitur Chest Pain Type (cp) yang awalnya memiliki nilai 0–3 diubah menjadi empat kolom baru: cp_0 (Typical Angina), cp_1 (Atypical

Angina), cp_2 (Non-Anginal), dan cp_3 (Asymptomatic). Hasil encoding dapat dilihat pada Table 4.1 berikut :

Tabel 4.1 Hasil Encoding

index	age	trestbps	chol	thalach	target	sex 0	sex 1	restecg 0	restecg 1	restecg 2	exang 0	exang 1	ca 0	ca 1	ca 2	ca 3	cp 0	cp 1	cp 2	cp 3
1	63	145	233	150	0	0	1	0	0	1	1	0	1	0	0	0	1	0	0	0
2	67	160	286	108	1	0	1	0	0	1	0	1	0	0	0	1	0	0	0	1
3	67	120	229	129	1	0	1	0	0	1	0	1	0	0	1	0	0	0	0	1
4	37	130	250	187	0	0	1	1	0	0	1	0	1	0	0	0	0	0	1	0
...
50	65	140	417	157	0.8	0	1	0	0	0	1	1	0	0	1	0	0	0	0	1
51	53	130	197	152	1.2	0	0	1	0	0	1	1	0	1	0	0	0	0	0	1
52	41	105	198	168	0	0	1	0	1	0	0	1	0	0	1	0	0	0	1	0
...
100	52	134	201	158	0.8	0	0	1	1	0	0	1	0	0	1	0	0	0	1	0
101	48	122	222	186	0	0	0	1	0	0	1	1	0	1	0	0	0	0	0	0
102	45	115	260	185	0	0	0	1	0	0	1	1	0	1	0	0	0	0	0	0
...
150	45	128	308	170	0	0	0	1	0	0	1	1	0	1	0	0	0	0	1	0
151	60	102	318	160	0	0	1	0	1	0	0	1	0	0	1	0	0	0	0	1
152	52	152	298	178	1.2	0	0	1	1	0	0	1	0	1	0	0	0	1	0	0
...
277	64	170	227	155	0.6	0	0	1	0	0	1	1	0	1	0	0	0	1	0	0
278	66	146	278	152	0	0	1	0	0	0	1	1	0	0	1	0	0	0	0	1
279	39	138	220	152	0	0	1	0	1	0	0	1	0	1	0	0	0	0	0	1
...
301	68	144	193	141	3.4	1	0	1	1	0	0	1	0	0	0	1	0	0	0	0
302	57	130	131	115	1.2	1	0	1	1	0	0	0	1	0	1	0	0	0	0	0
303	57	130	236	174	0	1	1	0	0	0	1	1	0	0	1	0	0	0	1	0
304	38	138	175	173	0	0	0	1	1	0	0	1	0	1	0	0	0	0	0	1

Melalui proses encoding tersebut, seluruh variabel kategorikal berhasil diubah menjadi bentuk numerik yang kompatibel dengan model Neural Network. Dataset yang telah terstandarisasi ini kemudian dilanjutkan ke tahap normalisasi dan pembagian data sebelum digunakan dalam proses pelatihan model.

4.2.3 Normalisasi

Langkah selanjutnya adalah melakukan normalisasi data numerik agar seluruh fitur berada dalam skala yang sama. Normalisasi diterapkan pada atribut numerik seperti age, trestbps, chol, thalach, dan oldpeak. Setelah proses ini, seluruh nilai diubah ke dalam rentang 0 hingga 1 menggunakan metode Min-Max Scaling. Dengan normalisasi ini, tidak ada fitur yang mendominasi proses pembelajaran model karena perbedaan skala. Sebagai contoh, nilai usia 63 tahun yang sebelumnya bernilai besar menjadi sekitar 0.70 setelah dinormalisasi ke dalam skala baru. Hasil normalisasi dapat dilihat pada table 4.2 berikut:

Tabel 4.2 Hasil Normalisasi

index	age	Trestbps	chol	thalach	target	sex_0	sex_1	restecg_0	restecg_1	restecg_2	exang_0	exang_1	ca_0	ca_1
1	0.708333333	0.481132075	0.244292237	0.603053435	0.370967742	0	0	1	0	0	1	1	0	1
2	0.791666667	0.622641509	0.365296804	0.282442748	0.241935484	1	0	1	0	0	1	0	1	0
3	0.791666667	0.245283019	0.235159817	0.442748092	0.419354839	1	0	1	0	0	1	0	1	0
4	0.166666667	0.339622642	0.283105023	0.885496183	0.564516129	0	0	1	1	0	0	1	0	1
...
50	0.75	0.433962264	0.664383562	0.65648855	0.129032258	0	1	0	0	0	1	1	0	0
51	0.5	0.339622642	0.162100457	0.618320611	0.193548387	0	0	1	0	0	1	1	0	1
52	0.25	0.103773585	0.164383562	0.740458015	0	0	1	0	1	0	0	1	0	0
...
100	0.479166667	0.377358491	0.171232877	0.664122137	0.129032258	0	0	1	1	0	0	1	0	0
101	0.395833333	0.264150943	0.219178082	0.877862595	0	0	0	1	0	0	1	1	0	1
102	0.333333333	0.198113208	0.305936073	0.870229008	0	0	0	1	0	0	1	1	0	1
...
150	0.333333333	0.320754717	0.415525114	0.755725191	0	0	0	1	0	0	1	1	0	1
151	0.645833333	0.075471698	0.438356164	0.679389313	0	0	1	0	1	0	0	1	0	0
152	0.479166667	0.547169811	0.392694064	0.816793893	0.193548387	0	0	1	1	0	0	1	0	1
...
277	0.729166667	0.716981132	0.230593607	0.641221374	0.096774194	0	0	1	0	0	1	1	0	1
278	0.770833333	0.490566038	0.347031963	0.618320611	0	0	1	0	0	0	1	1	0	0
279	0.208333333	0.41509434	0.214611872	0.618320611	0	0	1	0	1	0	0	1	0	1
...
301	0.471698113	0.152968037	0.534351145	0.548387097	1	0	1	1	0	0	1	0	0	0
302	0.339622642	0.011415525	0.335877863	0.193548387	1	0	1	1	0	0	0	1	0	1
303	0.339622642	0.251141553	0.786259542	0	1	1	0	0	0	1	1	0	0	1

Dengan normalisasi ini, seluruh fitur numerik berada dalam rentang skala yang seragam, sehingga proses pelatihan model menjadi lebih stabil dan cepat konvergen. Dataset yang telah dinormalisasi selanjutnya digunakan dalam tahap pelatihan model Neural Network.

4.3 Hasil

Tahapan ini menjelaskan hasil dari dua skenario pengujian yang telah dirancang sebelumnya. Pengujian dilakukan untuk mengetahui sejauh mana model Neural Network (Multi-Layer Perceptron/MLP) mampu melakukan prediksi penyakit jantung secara akurat, serta bagaimana hasil prediksi tersebut dapat dijelaskan secara transparan melalui metode Explainable Artificial Intelligence (XAI) menggunakan SHAP (Shapley Additive Explanations).

Melalui dua skenario ini, diharapkan dapat diperoleh gambaran yang menyeluruh mengenai performa dan interpretabilitas model. Skenario pertama berfokus pada evaluasi performa model MLP, meliputi proses pelatihan, validasi, serta pengujian menggunakan metrik akurasi, presisi, recall, F1-score, dan AUC. Tahap ini bertujuan untuk memastikan bahwa model yang dibangun mampu mengenali pola data medis dengan baik dan menghasilkan prediksi yang konsisten pada data uji.

Sementara itu, skenario kedua berfokus pada proses interpretasi hasil model dengan menggunakan metode Explainable AI, yaitu SHAP. Pendekatan ini dilakukan untuk menjelaskan bagaimana setiap fitur dalam data, seperti tekanan darah, detak jantung maximums, jenis nyeri dada, atau kadar kolesterol, memberikan kontribusi terhadap keputusan model. Dengan adanya interpretasi ini,

hasil prediksi yang sebelumnya bersifat “black box” dapat diuraikan dan dipahami secara logis, sehingga model tidak hanya akurat secara numerik tetapi juga transparan dan dapat dipercaya dari sisi klinis maupun etika penggunaan AI di bidang kesehatan.

4.3.1 Hasil Skenario 1

Pada skenario pertama dilakukan eksperimen untuk menganalisis pengaruh jumlah hidden layer dan jumlah neuron terhadap performa model Multi-Layer Perceptron (MLP) dalam memprediksi risiko penyakit jantung. Eksperimen ini bertujuan untuk memperoleh konfigurasi arsitektur yang mampu memberikan performa prediksi optimal dengan kompleksitas model yang tetap efisien.

Dataset yang digunakan merupakan Heart Disease Dataset yang telah melalui tahap preprocessing berupa encoding variabel kategorikal dan normalisasi fitur numerik. Dataset terdiri dari 303 data pasien dengan 31 atribut fitur serta satu variabel target biner yang menunjukkan risiko penyakit jantung koroner (0 = tidak berisiko, 1 = berisiko). Data kemudian dibagi menjadi data pelatihan dan data pengujian, di mana evaluasi performa dilakukan menggunakan data pengujian sebanyak 61 sampel.

Pada skenario ini dilakukan beberapa percobaan dengan variasi jumlah hidden layer dan neuron pada setiap layer. Seluruh model dilatih menggunakan parameter pelatihan yang sama, yaitu optimizer Adam, fungsi loss Binary Cross Entropy, batch size sebesar 32, serta mekanisme early stopping untuk mencegah overfitting. Fungsi aktivasi pada hidden layer ditetapkan menggunakan ReLU, sedangkan output layer menggunakan fungsi aktivasi sigmoid.

Eksperimen dilakukan dengan beberapa konfigurasi arsitektur jaringan yang meliputi satu hidden layer, dua *hidden layer* dan tiga *hidden layer* dengan jumlah neuron yang berbeda. Variasi konfigurasi bertujuan untuk mengamati pengaruh kompleksitas jaringan terhadap kemampuan model dalam mempelajari pola data medis.

Tabel 4.3 Konfigurasi Eksperimen MLP

Model	Hidden Layer	Konfigurasi
M1	1	8
M2	1	16
M3	1	32
M4	1	64
M5	1	128
M6	2	8-8
M7	2	16-8
M8	2	16-16
M9	2	32-16
M10	2	32-32
M11	2	64-32
M12	2	64-64
M13	2	128-64
M14	2	128-128
M15	3	32-16-8
M16	3	64-32-8
M17	3	128-64-32
M18	3	64-32-32
M19	3	128-64-64

Hasil evaluasi performa model pada setiap konfigurasi yang ditunjukkan pada Tabel 4.3. Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, F1-score, serta Area Under Curve (AUC).

Tabel 4.4 Hasil Eksperimen

Model	Arsitektur	Accuracy	precision	recall	F1-score	AUC
M1	8	0.87	0.87	0.87	0.87	0.9524
M2	16	0.87	0.87	0.87	0.87	0.9600
M3	32	0.84	0.84	0.84	0.84	0.9459
M4	64	0.85	0.85	0.86	0.85	0.9556
M5	128	0.87	0.87	0.87	0.87	0.9524
M6	8-8	0.89	0.89	0.88	0.88	0.9578
M7	16-8	0.87	0.87	0.87	0.87	0.9524
M8	16-16	0.90	0.90	0.90	0.90	0.9578
M9	32-16	0.87	0.87	0.87	0.87	0.9416
M10	32-32	0.87	0.87	0.87	0.87	0.9567
M11	64-32	0.90	0.90	0.90	0.90	0.9578
M12	64-64	0.87	0.87	0.87	0.87	0.9524
M13	128-64	0.89	0.89	0.89	0.89	0.9567
M14	128-128	0.89	0.89	0.89	0.89	0.9481
M15	32-16-8	0.87	0.87	0.87	0.87	0.9567
M16	64-32-8	0.89	0.89	0.89	0.89	0.9545
M17	128-64-32	0.87	0.87	0.87	0.87	0.9524
M18	64-32-32	0.89	0.89	0.89	0.89	0.9567
M19	128-64-64	0.87	0.87	0.87	0.87	0.9570

Berdasarkan hasil pengujian pada Tabel 4.4, terlihat bahwa peningkatan jumlah neuron pada satu hidden layer memberikan peningkatan performa hingga konfigurasi tertentu. Model dengan jumlah neuron yang terlalu kecil cenderung memiliki akurasi lebih rendah karena kapasitas jaringan belum cukup untuk menangkap pola kompleks pada data medis. Namun, peningkatan jumlah neuron yang terlalu besar tidak selalu menghasilkan peningkatan performa yang signifikan.

Penggunaan dua hidden layer menunjukkan peningkatan performa dibandingkan satu hidden layer, yang mengindikasikan bahwa penambahan kedalaman jaringan membantu model dalam membentuk representasi fitur yang lebih baik. Konfigurasi 16–16 dan 64–32 menghasilkan performa tertinggi dengan nilai accuracy sebesar 0.90 dan AUC sebesar 0.9578.

Meskipun kedua arsitektur tersebut memiliki performa yang sama, konfigurasi 16–16 dipandang lebih optimal karena memiliki kompleksitas model yang lebih rendah. Model dengan jumlah parameter yang lebih sedikit cenderung memiliki kemampuan generalisasi yang lebih baik serta risiko overfitting yang lebih kecil pada dataset berukuran terbatas.

Hasil ini menunjukkan bahwa peningkatan kompleksitas jaringan tidak selalu berbanding lurus dengan peningkatan performa prediksi. Pada dataset tabular berukuran kecil seperti dataset penyakit jantung, arsitektur jaringan yang lebih sederhana dapat memberikan hasil yang setara dengan model yang lebih kompleks.

Berdasarkan eksperimen arsitektur yang dilakukan, konfigurasi Multi-Layer Perceptron dengan dua hidden layer dan 16–16 neuron dipilih sebagai arsitektur terbaik pada penelitian ini. Model tersebut memberikan keseimbangan antara performa prediksi yang tinggi dan kompleksitas model yang relatif rendah. Arsitektur terpilih selanjutnya digunakan pada skenario pengujian berikutnya untuk mengevaluasi pengaruh fungsi aktivasi dan proses interpretasi menggunakan metode SHAP.

Setelah diperoleh konfigurasi arsitektur terbaik pada skenario sebelumnya, dilakukan eksperimen lanjutan untuk menganalisis pengaruh fungsi aktivasi terhadap performa model Multi-Layer Perceptron dalam memprediksi risiko penyakit jantung. Eksperimen ini bertujuan untuk mengetahui fungsi aktivasi yang paling efektif dalam membantu proses pembelajaran jaringan saraf pada data medis tabular.

Pengujian fungsi aktivasi dilakukan menggunakan arsitektur terbaik hasil Skenario 1, yaitu model dengan dua hidden layer dan konfigurasi neuron 16–16. Seluruh parameter pelatihan lainnya dipertahankan sama, meliputi optimizer Adam, fungsi loss Binary Cross Entropy, batch size sebesar 32, serta mekanisme early stopping. Dengan demikian, perbedaan performa model hanya dipengaruhi oleh perubahan fungsi aktivasi. Hasil evaluasi performa model untuk setiap fungsi aktivasi ditunjukkan pada Tabel 4.5.

Tabel 4.5 Hasil Eksperimen Fungsi Aktivasi

Aktivasi	Accuracy	Precision	Recall	F1-score	AUC
ReLU	0.90	0.90	0.90	0.90	0.95789
Tanh	0.89	0.89	0.89	0.89	0.9426
Sigmoid	0.87	0.87	0.87	0.87	0.9556
Leaky ReLU	0.87	0.87	0.87	0.87	0.9524

Berdasarkan hasil pengujian, fungsi aktivasi ReLU menghasilkan performa terbaik dengan nilai accuracy sebesar 0.90 dan AUC sebesar 0.9578. Nilai precision dan recall yang seimbang pada kedua kelas menunjukkan bahwa model mampu mengklasifikasikan pasien berisiko maupun tidak berisiko secara stabil.

Fungsi aktivasi Tanh menunjukkan performa yang sedikit lebih rendah dibandingkan ReLU. Hal ini dapat disebabkan oleh sifat fungsi Tanh yang menghasilkan nilai output pada rentang -1 hingga 1 sehingga proses pembelajaran menjadi lebih sensitif terhadap distribusi data.

Sementara itu, fungsi aktivasi Sigmoid dan Leaky ReLU menghasilkan performa yang relatif lebih rendah. Aktivasi sigmoid pada hidden layer cenderung mengalami permasalahan vanishing gradient, sehingga pembelajaran jaringan menjadi kurang optimal. Pada Leaky ReLU, meskipun mampu mengatasi neuron

mati (dying ReLU), peningkatan performa tidak terlihat signifikan pada dataset berukuran kecil seperti penelitian ini.

Hasil eksperimen menunjukkan bahwa fungsi aktivasi memiliki pengaruh terhadap stabilitas pembelajaran model, namun peningkatan kompleksitas fungsi aktivasi tidak selalu menghasilkan peningkatan performa prediksi.

Berdasarkan perbandingan performa seluruh fungsi aktivasi, ReLU dipilih sebagai fungsi aktivasi terbaik pada penelitian ini. Selain memberikan performa tertinggi, ReLU juga memiliki keunggulan dalam efisiensi komputasi serta stabilitas proses pelatihan. Model akhir yang digunakan pada tahap interpretasi Explainable AI (SHAP) adalah Multi-Layer Perceptron dengan konfigurasi:

1. Hidden layer : 2 layer
2. Neuron : 16–16
3. Aktivasi hidden layer : ReLU
4. Aktivasi output : Sigmoid

Konfigurasi tersebut memberikan keseimbangan antara akurasi prediksi dan kompleksitas model, sehingga dianggap paling optimal untuk dataset penyakit jantung yang digunakan.


4.3.2 Hasil Skenario 2

Pada skenario kedua, dilakukan pengujian terhadap model terbaik Multi-Layer Perceptron (MLP) yang diperoleh dari hasil eksperimen hyperparameter pada Skenario 1. Model ini menggunakan konfigurasi dua hidden layer (16 neuron dan 16 neuron), fungsi aktivasi ReLU pada hidden layer, serta dropout sebesar 0,2 untuk mencegah overfitting. Proses pelatihan dilakukan selama maksimal 100 epoch

dengan ukuran batch 32, dan menerapkan early stopping untuk menghentikan pelatihan jika akurasi validasi tidak meningkat lagi.

1. Pelatihan Model

Pada Gambar 4.2 menunjukkan grafik perubahan nilai training loss dan validation loss selama proses pelatihan model Multi-Layer Perceptron. Terlihat bahwa nilai loss pada kedua data mengalami penurunan secara konsisten seiring bertambahnya epoch. Pada awal pelatihan, nilai loss masih relatif tinggi karena model belum mampu mengenali pola data secara optimal. Namun, setelah beberapa epoch, nilai loss menurun secara stabil hingga mencapai kondisi konvergen di sekitar epoch ke-70. Selisih antara training loss dan validation loss yang relatif kecil menunjukkan bahwa model mampu melakukan generalisasi dengan baik dan tidak mengalami overfitting secara signifikan. Hal ini mengindikasikan bahwa konfigurasi arsitektur dan parameter pelatihan yang digunakan sudah sesuai untuk dataset yang digunakan.



Gambar 4.2 Grafik Hasil Training and Validation Loss

Sementara itu, Gambar 4.3 memperlihatkan grafik training accuracy dan validation accuracy selama proses pelatihan model. Nilai akurasi meningkat secara bertahap dari awal pelatihan hingga mencapai stabilitas pada kisaran 0.89–0.90. Kurva akurasi pelatihan dan validasi bergerak hampir sejajar tanpa perbedaan yang signifikan, yang menunjukkan bahwa model tidak hanya mampu mempelajari data pelatihan dengan baik tetapi juga mempertahankan performa pada data validasi. Kondisi ini menandakan bahwa model memiliki kemampuan generalisasi yang baik serta proses pembelajaran berlangsung secara stabil tanpa indikasi underfitting maupun overfitting.

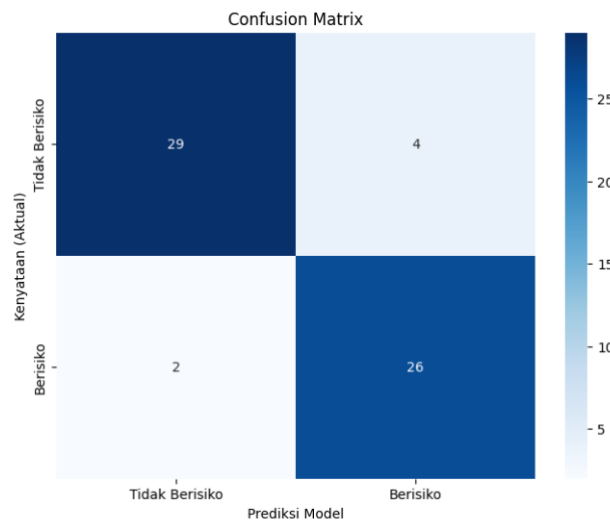


Gambar 4.3 Grafik Hasil Training and Validation Accuracy

2. Evaluasi Kinerja Model

Pada Gambar 4.4 menampilkan confusion matrix yang digunakan untuk mengevaluasi performa klasifikasi model terhadap data pengujian. Model berhasil mengklasifikasikan sebanyak 29 data pasien tidak berisiko dan 26 data pasien berisiko secara benar. Kesalahan klasifikasi relatif kecil, yaitu 4 data termasuk kategori false positive dan 2 data termasuk false negative. Nilai false negative yang

rendah menunjukkan bahwa model mampu mendeteksi sebagian besar pasien berisiko penyakit jantung, yang merupakan aspek penting dalam sistem prediksi medis karena kesalahan dalam mendeteksi pasien berisiko dapat berdampak serius terhadap proses diagnosis.



Gambar 4.4 Confusion Matrix

Hasil evaluasi juga didukung oleh laporan klasifikasi berikut:


Tabel 4.6 Hasil Laporan Klasifikasi

Kelas	Precision	Recall	F1-score	Support
Tidak Berisiko (0)	0.94	0.88	0.91	33
Berisiko (1)	0.87	0.93	0.90	28
Akurasi keseluruhan			0.90	61

Dari tabel di atas, dapat dilihat bahwa nilai precision dan recall seimbang, menunjukkan bahwa model tidak condong ke salah satu kelas. Nilai F1-score sebesar 0.90 juga menandakan bahwa model memiliki kemampuan prediksi yang baik dan stabil di kedua kelas.

3. Kurva ROC dan Nilai AUC

Untuk mengukur kemampuan model dalam membedakan antara pasien berisiko dan tidak berisiko, dilakukan analisis menggunakan kurva ROC (Receiver Operating Characteristic).



Gambar 4.5 ROC-AUC

Dari grafik pada Gambar 4.5 menunjukkan kurva Receiver Operating Characteristic (ROC) yang menggambarkan kemampuan model dalam membedakan kelas berisiko dan tidak berisiko pada berbagai nilai ambang klasifikasi. Kurva ROC terlihat mendekati sudut kiri atas, yang menandakan tingkat true positive rate yang tinggi dengan false positive rate yang rendah. Nilai Area Under Curve (AUC) sebesar 0.9578 menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat baik dalam melakukan klasifikasi. Hasil ini mengindikasikan bahwa model mampu memberikan prediksi yang akurat dan konsisten dalam membedakan pasien berisiko penyakit jantung dan tidak berisiko.

Berdasarkan hasil pengujian, dapat disimpulkan bahwa model dasar MLP memberikan performa yang sangat baik dengan akurasi 90% dan AUC 0.96. Nilai loss yang menurun stabil serta perbedaan kecil antara training dan validation

accuracy menunjukkan bahwa model mampu belajar dengan efektif tanpa mengalami overfitting. Hasil ini menunjukkan bahwa arsitektur MLP dengan dua hidden layer sudah cukup optimal dalam mendeteksi risiko penyakit jantung menggunakan dataset Heart Disease Cleveland.


4.3.3 Hasil Interpretasi SHAP

Pada proses interpretasi hasil model Neural Network menggunakan metode SHAP (Shapley Additive Explanations). Tujuan dari tahap ini adalah untuk memahami seberapa besar kontribusi masing-masing fitur medis terhadap hasil prediksi model, baik secara global maupun lokal.

Metode SHAP menghitung nilai kontribusi tiap fitur dengan cara membandingkan perubahan output model ketika fitur tersebut diaktifkan dan dinonaktifkan. Dengan demikian, setiap prediksi dapat dijelaskan melalui faktor-faktor yang paling berpengaruh.

1. Interpretasi Global

Interpretasi global digunakan untuk melihat fitur-fitur yang paling berpengaruh terhadap keseluruhan hasil prediksi model. Gambar 4.6 berikut menampilkan SHAP Summary Bar Plot, yang menggambarkan rata-rata nilai kontribusi setiap fitur terhadap output model.



Gambar 4.6 Interpretasi Global

Dari grafik terlihat bahwa beberapa fitur memiliki kontribusi yang dominan terhadap keputusan model, antara lain:

1. ca_0 (jumlah pembuluh darah besar = 0) menjadi fitur paling berpengaruh terhadap hasil prediksi. Nilai ini menunjukkan bahwa pasien dengan jumlah pembuluh darah besar normal (tidak tersumbat) memiliki dampak kuat terhadap klasifikasi model.
2. cp_3 (tipe nyeri dada asimtomatik) juga memiliki pengaruh besar terhadap peningkatan risiko. Nilai tinggi pada fitur ini sering diasosiasikan dengan kondisi penyakit jantung yang serius.
3. thal_3 (reversible defect) menunjukkan bahwa pasien dengan kelainan thalassemia yang bersifat reversibel cenderung diklasifikasikan sebagai berisiko oleh model.
4. slope_0 (kemiringan segmen ST meningkat) turut berperan signifikan, menunjukkan adanya hubungan antara hasil tes elektrokardiogram dan prediksi risiko jantung.

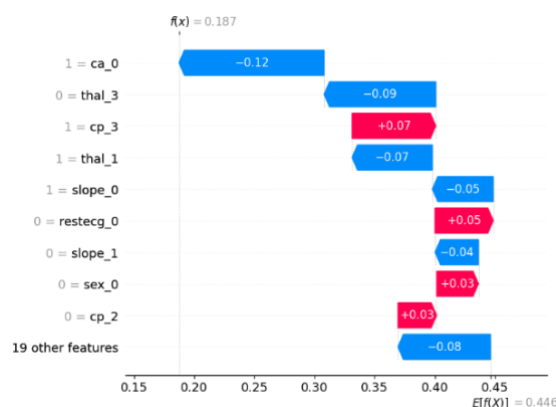
5. `thal_1` (normal thalassemia) dan `cp_2` (non-anginal pain) juga menunjukkan kontribusi moderat dalam memengaruhi hasil prediksi.

Secara umum, dapat dilihat bahwa fitur-fitur yang berkaitan langsung dengan kondisi jantung (seperti `cp`, `ca`, `thal`, dan `slope`) memiliki dampak paling signifikan terhadap hasil model. Hal ini memperlihatkan bahwa model tidak hanya mengandalkan variabel umum seperti usia atau tekanan darah, melainkan benar-benar mempelajari hubungan antarindikator klinis yang relevan secara medis.

Selain itu, fitur `oldpeak`, `restecg`, dan `exang` masih memiliki peran meskipun kontribusinya lebih kecil. Nilai-nilai ini menunjukkan bahwa model mampu mengintegrasikan berbagai faktor medis untuk menghasilkan prediksi yang lebih komprehensif.

2. Interpretasi Lokal

Selain analisis global, dilakukan pula interpretasi lokal untuk memahami bagaimana setiap fitur memengaruhi hasil prediksi pada satu individu tertentu. Pendekatan ini digunakan agar peneliti dapat melihat alasan di balik keputusan model terhadap satu kasus spesifik — apakah model memprediksi pasien tersebut berisiko atau tidak berisiko berdasarkan nilai fitur-fitur yang dimilikinya.



Gambar 4.7 Interpretasi Lokal

Berdasarkan Gambar 4.7 di atas, terlihat bahwa fitur-fitur dengan nilai berwarna merah memberikan kontribusi positif terhadap hasil prediksi (mendorong model ke arah kelas berisiko), sedangkan fitur-fitur dengan warna biru memberikan kontribusi negatif (menurunkan nilai prediksi risiko).

Pada contoh kasus ini, model menghasilkan nilai prediksi sebesar $f(x) = 0.187$, yang berarti probabilitas pasien tergolong rendah untuk diklasifikasikan sebagai berisiko. Dari grafik tersebut dapat diamati bahwa:

1. ca_0 (jumlah pembuluh darah besar = 0) memiliki kontribusi negatif terbesar (-0.12), menunjukkan bahwa kondisi pembuluh darah besar yang normal menurunkan kemungkinan risiko penyakit jantung.
2. $thal_3$ (reversible defect) juga memberikan kontribusi negatif (-0.09), menandakan bahwa tidak adanya kelainan thalassemia berat ikut memperkuat prediksi “tidak berisiko”.
3. Sebaliknya, fitur cp_3 (tipe nyeri dada asimtomatik) memberikan pengaruh positif ($+0.07$) karena tipe nyeri dada asimtomatik meningkatkan kecenderungan model untuk memprediksi pasien sebagai “berisiko”.
4. Fitur $restecg_0$ (elektrokardiografi) memberikan ($+0.05$) turut menambah sedikit nilai prediksi risiko, meskipun kontribusinya tidak sebesar faktor utama seperti cp dan ca .
5. Beberapa fitur lain seperti $thal_1$ (thalassemia normal), $slope_0$ (kemiringan segmen ST meningkat), dan cp_2 (Non-Anginal) memberikan pengaruh kecil dengan arah negatif, yang berarti mendukung keputusan model untuk memprediksi pasien ini sebagai tidak berisiko.

Secara umum, visualisasi ini memperlihatkan bagaimana model mempertimbangkan keseimbangan antara berbagai faktor medis untuk menentukan hasil akhir. Nilai negatif dominan dari fitur `ca_0`, `thal_3`, dan `slope_0` menyebabkan prediksi akhir mengarah ke kelas tidak berisiko, meskipun terdapat fitur positif seperti `cp_3` yang sedikit meningkatkan nilai risiko.

Hasil interpretasi lokal ini menunjukkan bahwa model tidak hanya memberikan hasil akhir, tetapi juga dapat menjelaskan alasan di balik prediksinya secara individual, sehingga mendukung transparansi dan akuntabilitas sistem kecerdasan buatan di bidang medis.

Berdasarkan hasil interpretasi model menggunakan metode SHAP (Shapley Additive exPlanations), dapat disimpulkan bahwa pendekatan Explainable AI ini berhasil memberikan pemahaman yang lebih mendalam mengenai cara kerja model Neural Network dalam memprediksi risiko penyakit jantung. Dengan adanya kemampuan interpretasi ini, hasil model tidak hanya berfungsi sebagai alat prediksi semata, tetapi juga dapat menjadi pendukung keputusan (decision support) bagi tenaga medis dalam menilai faktor-faktor risiko penyakit jantung model. Fitur-fitur ini merupakan indikator medis yang secara klinis memang relevan terhadap kondisi jantung, sehingga menunjukkan bahwa model telah mempelajari hubungan yang logis dan bermakna dari data.

Sementara itu, analisis lokal menunjukkan bagaimana kombinasi nilai setiap fitur pada individu tertentu dapat memengaruhi keputusan akhir model. Faktor seperti `ca_0` dan `thal_3` berperan menurunkan tingkat risiko, sedangkan `cp_3` dan `restecg_0` cenderung meningkatkan nilai probabilitas risiko. Visualisasi SHAP

membantu menjelaskan bahwa keputusan model bukan sekadar hasil perhitungan kompleks, tetapi dapat diurai dan dijelaskan secara terperinci untuk setiap pasien.

Penerapan metode SHAP ini membuktikan bahwa sistem prediksi berbasis AI dapat dibuat lebih transparan, etis, dan dapat dipertanggungjawabkan. Dengan adanya kemampuan interpretasi ini, hasil model tidak hanya berfungsi sebagai alat prediksi semata, tetapi juga dapat menjadi pendukung keputusan (decision support) bagi tenaga medis dalam menilai faktor-faktor risiko penyakit jantung.

4.4 Pembahasan

Bagian ini membahas hasil pengujian model yang telah dilakukan pada dua skenario sebelumnya, meliputi analisis performa model Neural Network (MLP) serta interpretasi hasil menggunakan metode Explainable AI (SHAP). Pembahasan dilakukan dengan mengaitkan antara hasil pengujian kuantitatif dan penjelasan interpretatif agar diperoleh pemahaman yang lebih menyeluruh mengenai kinerja model dalam memprediksi risiko penyakit jantung.

4.4.1 Hasil Pengaruh Variasi Arsitektur dan Fungsi Aktivasi

Eksperimen pada Skenario 1 dilakukan untuk menganalisis pengaruh variasi arsitektur Multi-Layer Perceptron (MLP), yang meliputi jumlah hidden layer dan jumlah neuron pada setiap layer, terhadap performa model dalam memprediksi risiko penyakit jantung. Berdasarkan hasil pengujian pada Tabel 4.4, terlihat bahwa perubahan arsitektur jaringan memberikan pengaruh terhadap performa model, meskipun perbedaannya tidak selalu signifikan pada seluruh konfigurasi.

Pada arsitektur dengan satu hidden layer, performa model berada pada kisaran akurasi 84%–87% dengan nilai AUC antara 0,94 hingga 0,96. Konfigurasi dengan 16 neuron (M2) menghasilkan nilai AUC tertinggi sebesar 0,96, sementara peningkatan jumlah neuron hingga 128 tidak menunjukkan peningkatan performa yang berarti. Hal ini menunjukkan bahwa penambahan neuron secara berlebihan tidak selalu meningkatkan kemampuan model dalam mempelajari pola data, terutama pada dataset berukuran relatif kecil.

Penggunaan dua hidden layer menunjukkan peningkatan performa yang lebih stabil dibandingkan satu hidden layer. Beberapa konfigurasi seperti 8–8, 32–32, 128–64, dan 128–128 menghasilkan akurasi pada kisaran 87%–89% dengan nilai AUC mendekati 0,96. Kondisi ini mengindikasikan bahwa penambahan kedalaman jaringan membantu model membentuk representasi fitur yang lebih baik tanpa meningkatkan kompleksitas secara berlebihan. Di antara seluruh konfigurasi dua hidden layer, arsitektur 16–16 (M8) dan 64–32 (M11) memberikan performa terbaik dengan akurasi dan F1-score sebesar 90% serta nilai AUC sebesar 0,9578. Kedua konfigurasi tersebut menunjukkan keseimbangan yang optimal antara kapasitas model dan kemampuan generalisasi.

Sebaliknya, peningkatan kompleksitas jaringan melalui penggunaan tiga hidden layer tidak memberikan peningkatan performa yang signifikan. Arsitektur seperti 32–16–8, 128–64–32, dan 128–64–64 menghasilkan akurasi yang kembali berada pada kisaran 87%, sedangkan konfigurasi 64–32–8 dan 64–32–32 hanya mencapai akurasi sekitar 89%. Hasil ini menunjukkan bahwa penambahan layer

yang terlalu dalam pada dataset tabular berukuran kecil cenderung tidak memberikan keuntungan tambahan dan bahkan dapat menurunkan efisiensi model.

Secara umum, hasil eksperimen arsitektur menunjukkan bahwa peningkatan kompleksitas jaringan tidak selalu berbanding lurus dengan peningkatan performa prediksi. Model dengan arsitektur menengah justru mampu memberikan hasil yang lebih optimal dibandingkan jaringan yang terlalu sederhana maupun terlalu kompleks. Oleh karena itu, arsitektur dua hidden layer dipilih sebagai kandidat terbaik untuk tahap eksperimen berikutnya.

Pada tahap selanjutnya dilakukan pengujian fungsi aktivasi menggunakan arsitektur terbaik yang diperoleh dari eksperimen arsitektur. Pengujian menunjukkan bahwa fungsi aktivasi sigmoid dan tanh menghasilkan performa yang cukup stabil dengan akurasi masing-masing sebesar 87% dan 89%. Namun, kedua fungsi aktivasi tersebut menunjukkan kecenderungan performa yang sedikit lebih rendah dibandingkan fungsi aktivasi berbasis ReLU. Hal ini dapat disebabkan oleh sifat fungsi sigmoid dan tanh yang lebih rentan terhadap permasalahan vanishing gradient, sehingga proses pembelajaran menjadi kurang optimal pada jaringan multilayer.

Sebaliknya, fungsi aktivasi ReLU memberikan performa terbaik dengan akurasi dan F1-score sebesar 90% serta nilai AUC mencapai 0,9578. ReLU mampu mempertahankan stabilitas gradien selama proses pelatihan sehingga pembelajaran berlangsung lebih efisien dan konvergen lebih cepat. Fungsi Leaky ReLU juga menunjukkan performa yang cukup baik dengan akurasi sebesar 87% dan AUC di atas 0,95, namun masih sedikit berada di bawah performa ReLU. Dalam konteks

prediksi medis, perbedaan performa meskipun kecil tetap menjadi pertimbangan penting karena dapat memengaruhi interpretasi tingkat risiko pasien.

Berdasarkan keseluruhan hasil eksperimen, konfigurasi arsitektur dua hidden layer dengan neuron 16–16 atau 64–32 serta fungsi aktivasi ReLU dipilih sebagai model terbaik. Model ini menunjukkan keseimbangan antara akurasi tinggi, stabilitas pelatihan, dan kompleksitas jaringan yang efisien. Dengan demikian, model yang digunakan pada tahap selanjutnya bukan merupakan hasil pemilihan secara intuitif, melainkan berdasarkan proses eksplorasi arsitektur dan hyperparameter yang sistematis dan didukung oleh bukti empiris. Model akhir ini kemudian digunakan pada tahap interpretasi Explainable Artificial Intelligence menggunakan metode SHAP untuk memahami kontribusi setiap fitur terhadap prediksi risiko penyakit jantung.

4.4.2 Analisis Performa Model

Berdasarkan hasil pengujian pada skenario evaluasi model, Multi-Layer Perceptron (MLP) menunjukkan performa klasifikasi yang sangat baik dengan nilai akurasi sebesar 0,90 dan nilai Area Under Curve (AUC) sebesar 0,9578. Nilai akurasi tersebut menunjukkan bahwa model mampu melakukan klasifikasi dengan benar pada sekitar 90% data pengujian, sedangkan nilai AUC yang mendekati angka 1 mengindikasikan kemampuan model yang sangat baik dalam membedakan pasien berisiko dan tidak berisiko penyakit jantung.

Grafik training loss dan validation loss memperlihatkan tren penurunan yang stabil sepanjang proses pelatihan. Kedua kurva menunjukkan pola yang relatif sejajar tanpa adanya peningkatan signifikan pada validation loss di akhir pelatihan.

Kondisi ini mengindikasikan bahwa model tidak mengalami overfitting dan mampu mempertahankan kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Stabilitas proses pelatihan juga diperkuat oleh konvergensi model pada epoch akhir, yang menunjukkan bahwa parameter jaringan telah mencapai kondisi optimal.

Selain itu, grafik training accuracy dan validation accuracy menunjukkan peningkatan performa yang konsisten hingga mencapai nilai stabil pada kisaran 0,89–0,90. Perbedaan yang kecil antara akurasi pelatihan dan validasi menunjukkan bahwa model tidak hanya menghafal data pelatihan, tetapi juga mampu mempelajari pola umum pada dataset secara efektif.

Berdasarkan confusion matrix, model berhasil mengklasifikasikan sebagian besar data dengan benar, dengan jumlah kesalahan prediksi yang relatif kecil. Model menghasilkan empat false positive dan dua false negative. Nilai false negative yang rendah menunjukkan bahwa model mampu mendeteksi sebagian besar pasien berisiko penyakit jantung, yang menjadi aspek penting dalam sistem prediksi medis karena kegagalan mendeteksi pasien berisiko dapat berdampak pada keterlambatan penanganan klinis.

4.4.3 Analisis Interpretasi

Pada Skenario 3, dilakukan analisis interpretasi model menggunakan metode SHAP. Hasil analisis menunjukkan bahwa fitur-fitur dengan kontribusi tertinggi terhadap hasil prediksi adalah ca_0 (jumlah pembuluh darah besar = 0), cp_3 (tipe nyeri dada asimtomatik), $thal_3$ (reversible defect) , dan $slope_0$ (kemiringan segmen ST meningkat). Hal ini sesuai dengan teori medis, di mana

nyeri dada (chest pain) merupakan salah satu indikator utama penyakit jantung (Kerr et al., 2023). Kelainan darah seperti thalassemia juga diketahui dapat menyebabkan gangguan jantung dan perubahan sinyal pada ECG (Aessopos et al., 2009). Selain itu, hasil elektrokardiogram dan segmen ST telah terbukti menjadi indikator penting dalam mendeteksi disfungsi jantung (Raghunath et al., 2020).

Nilai SHAP global memperlihatkan bahwa model benar-benar belajar dari pola medis yang logis dan relevan, bukan sekadar menghafal data. Sementara itu, interpretasi lokal memperlihatkan bagaimana kombinasi nilai-nilai fitur pada individu tertentu memengaruhi hasil prediksi secara personal. Misalnya, pasien dengan `ca_0` dan `thal_3` normal cenderung diprediksi tidak berisiko, meskipun terdapat faktor-faktor lain yang sedikit meningkatkan nilai risiko seperti `cp_3` atau `restecg_0`.

Dengan demikian, metode SHAP memberikan kejelasan bahwa model Neural Network yang dibangun tidak hanya akurat, tetapi juga dapat dijelaskan secara transparan (explainable). Hal ini penting agar hasil sistem prediksi dapat diterima dan dipercaya dalam konteks medis, terutama sebagai sistem pendukung keputusan bagi tenaga Kesehatan (Chebanyuk, 2024).

4.5 Integrasi Islam dan Sains

Penerapan teknologi kecerdasan buatan dalam penelitian ini tidak hanya dilihat dari sisi teknis dan akurasi semata, tetapi juga dikaitkan dengan nilai-nilai Islam yang menekankan pentingnya tanggung jawab, kejujuran, dan kemaslahatan umat manusia. Integrasi antara Islam dan sains dalam konteks ini menyoroti bagaimana penerapan Artificial Intelligence dapat digunakan sebagai sarana

ikhfifh al-nafs (menjaga jiwa), yang merupakan salah satu tujuan utama dalam maqashidm firman Allah Swt. pada QS. Al-Baqarah ayat 195:

وَأَنْفِقُوا فِي سَبِيلِ اللَّهِ وَلَا تُلْقُوا بِأَيْدِيكُمْ إِلَى التَّهْلُكَةِ وَأَحْسِنُوا إِنَّ اللَّهَ يُحِبُّ الْمُحْسِنِينَ

“Dan janganlah kamu menjatuhkan dirimu sendiri ke dalam kebinasaan, dan berbuat baiklah, karena sesungguhnya Allah menyukai orang-orang yang berbuat baik.” (QS. Al-Baqarah: 195).

Ayat tersebut menjadi dasar moral bahwa menjaga kesehatan dan keselamatan jiwa termasuk bagian dari perintah agama (Ibnu Katsir & Ismail bin Umar., 2003). Dalam konteks penelitian ini, pengembangan model prediksi penyakit jantung dengan dukungan teknologi AI merupakan bentuk nyata dari upaya preventif (pencegahan) terhadap risiko penyakit yang dapat mengancam jiwa manusia. Dengan sistem ini, tenaga medis maupun pasien dapat memperoleh peringatan dini yang membantu pengambilan keputusan secara cepat dan akurat.

Selain itu, prinsip Explainable AI (SHAP) yang diterapkan juga sejalan dengan nilai-nilai transparansi dan keadilan dalam Islam. Islam mengajarkan agar setiap keputusan diambil berdasarkan penjelasan yang jelas (tabyin) dan tidak bersifat sembunyi-sembunyi. Hal ini relevan dengan tujuan SHAP yang berfungsi menjelaskan alasan di balik hasil prediksi model, sehingga pengguna dapat memahami dasar keputusan sistem. Dengan demikian, penelitian ini tidak hanya menonjolkan aspek kecerdasan buatan, tetapi juga menegaskan nilai akuntabilitas dan tanggung jawab ilmiah yang sangat penting dalam pandangan Islam.

Lebih jauh lagi, keberhasilan penelitian ini juga menunjukkan bahwa sains dan agama dapat berjalan beriringan. Sains berperan dalam memberikan solusi dan

inovasi melalui teknologi modern, sementara agama memberikan arah moral dan etika agar teknologi tersebut digunakan dengan bijak.

Penggunaan AI dalam bidang kesehatan harus diarahkan untuk kemaslahatan manusia (masalah al-nas), bukan sekadar untuk kepentingan ekonomi atau kompetisi teknologi. Dengan landasan nilai-nilai Islam, hasil penelitian seperti ini diharapkan dapat menjadi bagian dari amal shalih yakni usaha yang memberi manfaat bagi kehidupan banyak orang (Ibnu Katsir & Ismail bin Umar., 2003).

Dengan demikian, integrasi Islam dan sains dalam penelitian ini menegaskan bahwa kemajuan teknologi, termasuk dalam bidang kecerdasan buatan, harus selalu diiringi dengan nilai-nilai keimanan, kejujuran, dan tanggung jawab. AI bukan sekadar alat bantu analisis, tetapi juga wasilah (sarana) untuk menjaga kehidupan dan kesehatan manusia sesuai dengan prinsip *hifzh al-nafs* (menjaga jiwa), yang merupakan salah satu tujuan utama dalam *maqashid syariah*.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai Implementasi Neural Network untuk Prediksi Penyakit Jantung dengan Explainable AI (SHAP), dapat disimpulkan bahwa model Neural Network (Multi-Layer Perceptron/MLP) dengan dua hidden layer berisi 64 dan 32 neuron serta fungsi aktivasi ReLU berhasil memberikan performa yang sangat baik dalam mendeteksi risiko penyakit jantung. Hasil pengujian menunjukkan akurasi sebesar 90% dan nilai AUC sebesar 0.96, yang termasuk dalam kategori excellent classification performance. Selain itu, hasil interpretasi menggunakan metode SHAP (Shapley Additive Explanations) menunjukkan bahwa fitur-fitur medis seperti ca_0 (jumlah pembuluh darah besar = 0), cp_3 (tipe nyeri dada asimtomatik), thal_3 (reversible defect) , dan slope_0 (kemiringan segmen ST meningkat) memiliki pengaruh paling besar terhadap keputusan model. Hal ini membuktikan bahwa model tidak hanya akurat secara numerik, tetapi juga mampu memberikan penjelasan logis terhadap hasil prediksinya. Penerapan metode Explainable AI (XAI) dalam penelitian ini berhasil meningkatkan transparansi dan akuntabilitas model, sehingga hasil prediksi dapat dipahami dan dipercaya oleh tenaga medis. Dengan demikian, penelitian ini menunjukkan potensi besar integrasi kecerdasan buatan sebagai decision support system dalam bidang kesehatan.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, masih terdapat beberapa keterbatasan dalam penelitian ini, sehingga diperlukan kritik dan saran yang membangun agar dapat meningkatkan kualitas penelitian di masa mendatang. Berdasarkan hasil kesimpulan yang telah diperoleh dari skenario pengujian, beberapa saran yang dapat diberikan untuk pengembangan dan penelitian selanjutnya adalah sebagai berikut:

- a) Disarankan untuk menggunakan dataset yang lebih besar dan beragam, termasuk data lokal dari rumah sakit di Indonesia, agar hasil model dapat lebih representatif terhadap kondisi klinis di lapangan.
- b) Perlu dilakukan pengujian langsung (deployment) dalam bentuk sistem web atau aplikasi, sehingga hasil prediksi dan interpretasi SHAP dapat digunakan secara praktis oleh tenaga medis maupun pasien.
- c) Penggunaan metode Explainable AI lain seperti LIME, Grad-CAM, atau Integrated Gradients dapat menjadi bahan perbandingan untuk memperkuat aspek interpretabilitas.

DAFTAR PUSTAKA

- Abdellatif, A. O. H. (2024). *Enhanced Computational Methods for Detection and Interpretation of Heart Disease Based on Ensemble Learning and Autoencoder Framework*. search.proquest.com. <https://search.proquest.com/openview/9edf35810f70558ca28d40317806c746/1?pq-origsite=gscholar&cbl=2026366&diss=y>
- Ahsan, M. M., & Siddique, Z. (2022). Machine learning-based heart disease diagnosis: A systematic literature review. *Artificial Intelligence in Medicine*, 128, 102289. <https://doi.org/10.1016/J.ARTMED.2022.102289>
- Alsawaf, R. S., Dawood, R. F., Khalid, R. W., & Mahmood, M. B. (2024). The application of neural networks in diagnosing heart disease: A review. *International Journal of Medical and All Body Health Research*, 5(3), 08–15. <https://doi.org/10.54660/ijmbhr.2024.5.3.08-15>
- Chebanyuk, O. V. (2024). Agile requirement analysis approach using artificial intelligent technologies. *PROBLEMS IN PROGRAMMING*. <https://pp.isoftware.kiev.ua/index.php/ojs1/article/view/630>
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Al-Madeed, S., Zughair, S. M., Doi, S. A. R., Hassen, H., & Islam, M. T. (2024). An Early Warning Tool for Predicting Mortality Risk of COVID-19 Patients Using Machine Learning. *Cognitive Computation*, 16(4), 1778–1793. <https://doi.org/10.1007/s12559-020-09812-7>
- Damayanti, A. S. (2025). *Model Deteksi Penyakit Jantung Koroner dengan Principal Component Analysis dan Explainable AI untuk Interpretabilitas*. digilib.uns.ac.id. <https://digilib.uns.ac.id/dokumen/detail/125178/>
- Danu, M. R. F., & Agung, I. W. P. (2025). Rancangan Model Artificial Neural Network untuk Memprediksikan Penyakit Jantung Koroner di RSUD Zainoel Abidin Banda Aceh. *Economic Reviews Journal*. <http://www.mes-bogor.com/journal/index.php/mrj/article/view/626>
- Ibnu Katsir, & Ismail bin Umar. (2003). *Tafsir-Ibnu-Katsir-Jilid-1-Ibnu-Katsir-Z-Library*.
- Kaptoge, S., Pennells, L., De Bacquer, D., Cooney, M. T., Kavousi, M., Stevens, G., Riley, L. M., Savin, S., Khan, T., Altay, S., Amouyel, P., Assmann, G., Bell, S., Ben-Shlomo, Y., Berkman, L., Beulens, J. W., Björkelund, C., Blaha, M., Blazer, D. G., ... Di Angelantonio, E. (2019). World Health Organization cardiovascular disease risk charts: revised models to estimate risk in 21 global regions. *The Lancet Global Health*, 7(10), e1332–e1345. [https://doi.org/10.1016/S2214-109X\(19\)30318-3](https://doi.org/10.1016/S2214-109X(19)30318-3)

- Lundberg, S. M., Allen, P. G., & Lee, S.-I. (2021). *A Unified Approach to Interpreting Model Predictions*. <https://github.com/slundberg/shap>
- Mathur, P., Srivastava, S., Xu, X., & Mehta, J. L. (2020). Artificial Intelligence, Machine Learning, and Cardiovascular Disease. In *Clinical Medicine Insights: Cardiology* (Vol. 14). SAGE Publications Ltd. <https://doi.org/10.1177/1179546820927404>
- Muhammad Akram Fais, M. Revano Ananda Lubis, Annisa Aulia, & Indri Syafitri. (2023). Implementasi Algoritma Decision Tree untuk Klasifikasi Serangan Jantung. *Jurnal Sistem Informasi Dan Ilmu Komputer*, 1(4), 207–212. <https://doi.org/10.59581/jusiik-widyakarya.v1i4.1895>
- Muharram, F. R., Multazam, C. E. C. Z., Mustofa, A., Socha, W., Andrianto, Martini, S., Aminde, L., & Yi-Li, C. (2024). The 30 Years of Shifting in The Indonesian Cardiovascular Burden—Analysis of The Global Burden of Disease Study. *Journal of Epidemiology and Global Health*, 14(1), 193–212. <https://doi.org/10.1007/s44197-024-00187-8>
- Muliani, S., Negara, B. S., Irsyad, M., Jasril, J., & ... (2025). Application of Shapley Additive Explanations (SHAP) in Deep Learning for Lung Disease Detection Using X-ray Images. ... of *Artificial Intelligence* <https://ejournal.pnl.ac.id/JAISE/article/view/7044>
- Permana, A. A., Wiratama, J., Sutomo, R., Kristiyanti, D. A., & ... (2024). *Web and Mobile Designer User Experience*. repository.penerbiteureka.com. <https://repository.penerbiteureka.com/id/publications/569690/web-and-mobile-designer-user-experience>
- Raghunath, S., Ulloa Cerna, A. E., Jing, L., Vanmaanen, D. P., Stough, J., Hartzel, D. N., Leader, J. B., Kirchner, H. L., Good, C. W., Patel, A. A., Delisle, B. P., Alsaid, A., Beer, D., Haggerty, C. M., & Fornwalt, B. K. (2020). *Deep neural networks can predict mortality from 12-lead electrocardiogram voltage data*.
- Raharjo, M. R., Rahadjeng, I. R., Siregar, M. N. H., & Alkhairi, P. (2025). Optimasi Fungsi Aktivasi pada Artificial Neural Network untuk Prediksi Gagal Jantung Secara Akurat. *Explorer*. <https://journal.fkpt.org/index.php/Explorer/article/view/1840>
- Rahmada, A., & Susanto, E. R. (2025). Peningkatan Akurasi Prediksi Penyakit Jantung dengan Teknik SMOTEENN pada Algoritma Random Forest. *Jurnal Pendidikan Dan Teknologi Indonesia*, 4(12), 795–803. <https://doi.org/10.52436/1.jpti.524>
- Rajpurkar, P., Chen, E., Banerjee, O., & Topol, E. J. (2022). AI in health and medicine. *Nature Medicine*, 28(1), 31–38. <https://doi.org/10.1038/s41591-021-01614-0>

- Rasmy, L., Xiang, Y., Xie, Z., Tao, C., & Zhi, D. (2021). Med-BERT: pretrained contextualized embeddings on large-scale structured electronic health records for disease prediction. *Npj Digital Medicine*, 4(1), 86. <https://doi.org/10.1038/s41746-021-00455-y>
- Rizky Putri Soewarno, M., Ardianto, R., Suryani, R., Ridlo Al-Hakim, R., & Immanuel Wahyudi, C. (2023). *Analisis Perbandingan Algoritma KNN dan SVM untuk Prediksi Risiko Kesehatan Ibu Hamil*. <https://ejournal.uhb.ac.id/index.php/korisa>
- Roth, G. A., Mensah, G. A., Johnson, C. O., Addolorato, G., Ammirati, E., Baddour, L. M., Barengo, N. C., Beaton, A., Benjamin, E. J., Benziger, C. P., Bonny, A., Brauer, M., Brodmann, M., Cahill, T. J., Carapetis, J. R., Catapano, A. L., Chugh, S., Cooper, L. T., Coresh, J., ... Fuster, V. (2020). Global Burden of Cardiovascular Diseases and Risk Factors, 1990–2019: Update From the GBD 2019 Study. *Journal of the American College of Cardiology*, 76(25), 2982–3021. <https://doi.org/10.1016/J.JACC.2020.11.010>
- Serrano, D. R., Luciano, F. C., Anaya, B. J., Ongoren, B., Kara, A., Molina, G., Ramirez, B. I., Sánchez-Guirales, S. A., Simon, J. A., Tomietto, G., Rapti, C., Ruiz, H. K., Rawat, S., Kumar, D., & Lalatsa, A. (2024). Artificial Intelligence (AI) Applications in Drug Discovery and Drug Delivery: Revolutionizing Personalized Medicine. In *Pharmaceutics* (Vol. 16, Issue 10). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/pharmaceutics16101328>
- Shaaf, Z. (2023). *Convolutional Neural Network Model for Left Ventricle Segmentation to Detect Myocardial Infarction*. [search.proquest.com. https://search.proquest.com/openview/b73e0484a79d5e58d84334e04b71a447/1?pq-origsite=gscholar&cbl=2026366&diss=y](https://search.proquest.com/openview/b73e0484a79d5e58d84334e04b71a447/1?pq-origsite=gscholar&cbl=2026366&diss=y)
- So, S., Roslan Ismail, M., & Jaafar, S. (2021). Exploring Acceptance of Artificial Intelligence amongst Healthcare Personnel: A Case in a Private Medical Centre. *International Journal of Advances in Engineering and Management (IJAEM)*, 3, 2395–5252. <https://doi.org/10.35629/5252-03095665>
- Sza Amulya Larasati, S., Nuraida Kusuma Dewi, E., Hanif Farhansyah, B., Abdurrachman Bachtiar, F., Pradana, F., & Brawijaya, U. (2023). *PENERAPAN DECISION TREE DAN RANDOM FOREST DALAM DETEKSI TINGKAT STRES MANUSIA BERDASARKAN KONDISI TIDUR*. 10(7), 1503–1510. <https://doi.org/10.25126/jtiik.2023107993>
- Uli, R. E., Satyana, R. P. U., Zomer, E., Magliano, D., Liew, D., & Ademi, Z. (2020). Health and productivity burden of coronary heart disease in the working Indonesian population using life-table modelling. *BMJ Open*, 10(9). <https://doi.org/10.1136/bmjopen-2020-039221>

Yuda Syahidin, Aditya Pratama Ismail, & Fawwaz Nafis Siraj. (2022). Application of Artificial Neural Network Algorithms to Heart Disease Prediction Models with Python Programming. *Jurnal E-Komtek (Elektro-Komputer-Teknik)*, 6(2), 292–302. <https://doi.org/10.37339/e-komtek.v6i2.932>