

---

## Implementasi Artificial Intelligence untuk Prediksi Penyakit Jantung dengan Pendekatan Explainable AI

Bima Wahyu Maulana<sup>1</sup>, Agung Muliawan<sup>2</sup>, Muhammad Hafidh Firmansyah<sup>3</sup>, Angga Dwinanda<sup>4</sup>, Difari Afreyna Fauziah<sup>5</sup>

<sup>1,2,3,4</sup>Politeknik Negeri Jember

<sup>5</sup>Institut Teknologi dan Sains Mandala

e-mail: [bimawahyu.maulana@polije.ac.id](mailto:bimawahyu.maulana@polije.ac.id)<sup>1</sup>, [agung.muliawan@polije.ac.id](mailto:agung.muliawan@polije.ac.id)<sup>2</sup>, [hafidh@polije.ac.id](mailto:hafidh@polije.ac.id)<sup>3</sup>, [angga.dwinanda@polije.ac.id](mailto:angga.dwinanda@polije.ac.id)<sup>4</sup>, [difariafreyna@itsm.ac.id](mailto:difariafreyna@itsm.ac.id)<sup>5</sup>

---

### ABSTRAK

Penelitian ini menitikberatkan pada pengembangan sistem untuk memprediksi penyakit kardiovaskular melalui penerapan algoritma Random Forest. Peneliti mengintegrasikan pendekatan Explainable Artificial Intelligence (XAI) menggunakan metode SHAP (SHapley Additive exPlanations) guna mengatasi kendala "kotak hitam" pada sistem. Langkah tersebut memperkuat aspek transparansi model sehingga keputusan kecerdasan buatan menjadi lebih logis. Peneliti melakukan analisis dengan memanfaatkan data sekunder dari Heart Disease UCI Dataset. Kumpulan data ini memuat variabel klinis esensial yang meliputi umur, jenis kelamin, tekanan darah, hingga kadar kolesterol. Tahapan riset dimulai dari proses pra-pemrosesan data, pembagian data latih dan uji, hingga fase pembangunan model. Peneliti menguji efektivitas sistem melalui metrik akurasi, presisi, recall, serta F1-score. Temuan empiris membuktikan bahwa model mencapai tingkat akurasi sebesar 83 persen. Sistem tersebut menunjukkan kapabilitas klasifikasi yang stabil untuk mendeteksi pasien positif maupun negatif penyakit jantung. Lebih lanjut, penerapan SHAP mengungkap bahwa variabel oldpeak, thalach, dan ca menjadi determinan paling krusial dalam pembentukan prediksi. Menariknya, fitur seperti kolesterol tidak selalu memberikan dampak linier langsung, melainkan bekerja melalui interaksi kompleks dengan atribut lainnya. Secara keseluruhan, integrasi XAI dalam studi ini terbukti meningkatkan interpretabilitas model machine learning. Hal ini diharapkan dapat memberikan landasan klinis yang lebih kuat bagi tenaga medis dalam proses pengambilan keputusan serta mempertebal kepercayaan terhadap sistem diagnostik berbasis AI

**Kata kunci** : penyakit jantung, XAI, SHAP

### ABSTRACT

*This study focuses on the development of a system to predict cardiovascular disease through the application of Random Forest algorithm. The researcher integrated Explainable Artificial Intelligence (XAI) approach using SHAP (SHapley Additive exPlanations) method to overcome "black box" constraints on the system. The move strengthens the transparency aspect of the model so that artificial intelligence decisions become more logical. Researchers conducted the analysis by utilizing secondary data from the UCI Heart Disease Dataset. This data set contains essential clinical variables that include age, sex, blood pressure, to cholesterol levels. The research phase starts from the data pre-processing process, the distribution of training and test data, to the model development phase. Researchers tested the effectiveness of the system through metrics of accuracy, precision, recall, and F1-score. Empirical findings prove that the model achieves an accuracy rate of 83 percent. The system demonstrates stable classification capability to detect both positive and negative heart disease patients. Furthermore, the application of SHAP reveals that the variables oldpeak, thalach, and ca become the most crucial determinants in the formation of predictions. Interestingly, features such as cholesterol do not necessarily have a direct linear impact, but rather work through complex interactions with other attributes. Overall, the integration of XAI in this study was shown to improve the interpretability of machine learning models. This is expected to provide a stronger clinical foundation for medical personnel in the decision-making process as well as strengthen trust in AI-based diagnostic systems.*

**Keywords**: Heart disease, XAI, SHAP

## PENDAHULUAN

Explainable Artificial Intelligence (XAI) merupakan kumpulan metode dan kerangka kerja yang dapat diinterpretasikan oleh manusia. XAI dirancang dengan proses decision-making dari model Artificial Intelligence (AI) yang transparan. XAI memiliki empat tujuan yaitu meningkatkan kepercayaan, memfasilitasi verifikasi, mendukung kepatuhan, dan meningkatkan debugging [1]. Kepercayaan merupakan parameter penting yang membuat manusia dapat menentukan bergantung-tidaknya manusia pada penggunaan teknologi. Kepercayaan dilandasi juga dengan model yang transparan dan informatif yang dapat memastikan tidak akan ada pelatihan yang salah pada model AI. Model yang informatif juga menghindari dari manipulasi generalisasi model AI/Machine Learning (ML) yang cenderung menghasilkan keuntungan yang kurang etis dan hal ini mendukung fasilitas untuk verifikasi hasil AI. Kepatuhan dilandasi oleh justifikasi yang logis dan ilmiah dari hasil prediksi dan kesimpulan dari model AI serta dilandasi dengan pertukaran bias (bias and variance trade-off) di AI/ML yang membantu mengurangi bias prediksi. Peningkatan debugging dilandasi dengan transparansi yang mengurangi kerentanan prediksi [2].

Aplikasi XAI digunakan di beberapa bidang diantaranya di bidang lingkungan untuk mereproduksi peristiwa kebakaran di Eropa yang faktor lingkungannya diidentifikasi dengan SHAP [3], di bidang pendidikan penggunaan XAI digunakan untuk menganalisis tren pertumbuhan Learning Management System (LMS) dan Educational Data Mining (EDM) dan menjawab tuntutan kemampuan peningkatan penjelasan dalam pembelajaran dan pengajaran [4]. Di bidang sosial media, XAI digunakan untuk meningkatkan kemampuan menjelaskan bermacam-macam konteks yang dapat ditemui di media sosial [5]. Keamanan jaringan juga menggunakan XAI, yaitu model SHAP untuk deteksi malware, dan menunjukkan pentingnya fitur untuk klarifikasi model keputusan (decision model)[6]. Di bidang finansial penggunaan

XAI pada integrasi teknologi blockchain untuk pencatatan kas yang aman dan transparan dan didukung fitur pengambilan keputusan dengan pemodelan prediktif [7]. Penggunaan XAI di bidang pertanian diantaranya penggunaan sistem rekomendasi tanaman untuk menafsirkan model berdasarkan kebutuhan pertanian tertentu sesuai kebutuhan petani [8].

Bidang kesehatan adalah salah satu bidang yang cukup banyak diteliti dengan menggunakan berbagai model AI. Salah satu penyakit yang diteliti adalah penyakit jantung. Model AI digunakan untuk tiga hal yaitu prediksi, klasifikasi dan diagnosis pada penyakit jantung [9]. Algoritma Random Forest menunjukkan tingkat akurasi yang signifikan mencapai 92,3% saat mengklasifikasi parameter medis seperti tekanan darah, kolesterol, indeks massa tubuh (BMI), dan frekuensi nadi.[10], Melalui skema SMOTEENN, akurasi identifikasi risiko penyakit jantung menggunakan Random Forest berhasil dioptimalkan secara impresif, beralih dari tingkat ketepatan 86% menuju 94%. [11] Dibandingkan dengan model *Decision Tree* dan *Random Forest*, penelitian oleh Mikhael Chandra Arta dkk. menemukan bahwa Gradient Boosted merupakan algoritma yang paling kompeten. Berdasarkan pengujian terhadap variabel seperti tingkat glukosa, detak jantung, tekanan darah, dan indikator medis lainnya, sistem ini mencatatkan skor evaluasi tertinggi sebesar 86,6%. [12].

Beberapa penelitian XAI menunjukkan fungsi XAI dapat meningkatkan akurasi, presisi, recall, dan F1-Score pada prediksi penyakit jantung. M. Talukder et al., melaporkan bahwa framework XAI-HD mengurangi tingkat kesalahan klasifikasi dengan rentang 20-25% dibandingkan model machine learning tanpa menggunakan XAI (machine learning konvensional) [13]. Random forest yang dikombinasikan dengan teknik XAI mencapai AUC 0,99 dan akurasi 98,5% untuk prediksi penyakit jantung [14].

## METODE PENELITIAN

### Pengumpulan Dataset

Peneliti memulai langkah awal kegiatan melalui pengumpulan data penyakit jantung dari Heart Disease UCI Dataset. Data ini mencakup beragam parameter medis penting seperti umur, jenis kelamin, tekanan darah, kadar kolesterol, serta frekuensi detak jantung maksimal untuk keperluan prediksi. Peneliti menggunakan dataset tersebut karena memiliki atribut yang sangat relevan bagi kebutuhan klasifikasi serta menjadi rujukan utama dalam berbagai riset machine learning di bidang kesehatan [15]. Berikut Tabel sampel dataset yang digunakan :

Tabel 1. Sampel Dataset

No	1	2	3	4	5	6	7	8
age	52	53	70	61	62	58	58	55
sex	1	1	1	1	0	0	1	1
cp	0	0	0	0	0	0	0	0
trest	12	14	14	14	13	10	11	16
bps	5	0	5	8	8	0	4	0
chol	21	20	17	20	29	24	31	28
	2	3	4	3	4	8	8	9
fbs	0	1	0	0	1	0	0	0
reste	1	0	1	1	1	0	2	0
cg								
thala	16	15	12	16	10	12	14	14
ch	8	5	5	1	6	2	0	5
exan	0	1	1	0	0	0	0	1
g								
oldp	1.	3.	2.	0.	1.	1.	4.	0.
eak	0	1	6	0	9	0	4	8
slope	2	0	0	2	1	1	0	1
ca	2	0	0	1	3	0	3	1
thal	3	3	3	3	2	2	1	3
targe	0	0	0	0	0	1	0	0
t								

### Preprocessing Data

Fase prapemrosesan mencakup validasi nilai yang hilang serta transformasi data guna mendukung kinerja algoritma pembelajaran mesin. Tahap ini mengubah variabel target dari label kategoris "yes" dan "no" menjadi representasi angka 1 dan 0. Peneliti membagi dataset ke dalam kelompok data latih dan data uji menggunakan rasio 80:20. Data latih berperan

penting dalam proses konstruksi model. Di sisi lain, data uji menyediakan sarana objektif untuk mengevaluasi hasil pemodelan tersebut. Tahap preprocessing bertujuan agar data lebih bersih, konsisten, dan siap digunakan dalam proses pembangunan model machine learning

### Konstruksi Model Random Forest

Dalam fase ini, algoritma Random Forest diimplementasikan sebagai fondasi sistem prediksi. Pemilihan metode ini didasari oleh keunggulannya dalam melakukan klasifikasi pada dataset dengan dimensi fitur yang tinggi serta efektivitasnya dalam memitigasi risiko *overfitting*. Proses pengembangan dilakukan di lingkungan pemrograman Python dengan memanfaatkan pustaka *machine learning* standar. Model dikembangkan melalui fase pelatihan menggunakan dataset yang tersedia, yang kemudian divalidasi kemampuannya dalam mengenali pola data terkait indikasi penyakit jantung [16].

### Evaluasi Model

Untuk mengukur efektivitas dan keandalan model yang telah dibangun, dilakukan serangkaian pengujian kuantitatif. Parameter evaluasi yang digunakan meliputi confusion matrix, serta perhitungan nilai akurasi, precision, recall, dan F1-score. Metrik ini bertujuan untuk membedah sejauh mana model mampu membedakan kategori target secara akurat dan konsisten.

### Analisis Feature Importance

Langkah berikutnya adalah melakukan analisis terhadap tingkat kepentingan fitur. Tahapan ini bertujuan untuk memetakan variabel klinis mana saja yang memberikan pengaruh dominan atau kontribusi paling signifikan dalam menentukan hasil akhir prediksi risiko penyakit jantung. Implementasi

### Explainable Artificial Intelligence (XAI)

Penelitian ini mengadopsi teknik SHAP (*SHapley Additive exPlanations*) melalui kerangka Explainable Artificial Intelligence untuk menjamin transparansi sistem serta meniadakan sifat "black box". Penggunaan SHAP memungkinkan adanya visualisasi dan interpretasi logis di balik setiap keputusan yang diambil oleh model *machine learning*. Dengan demikian,

mekanisme internal prediksi menjadi lebih transparan dan dapat dipertanggungjawabkan secara klinis[17].

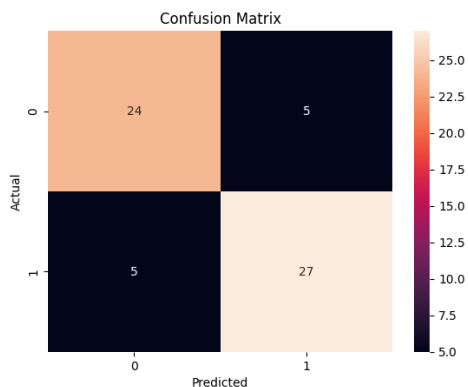
## HASIL DAN PEMBAHASAN

### Hasil Evaluasi Model

Berdasarkan hasil pengujian diperoleh nilai:

- True Negative (TN): 24
- False Positive (FP): 5
- False Negative (FN): 5
- True Positive (TP): 27

Selain itu, model memperoleh tingkat akurasi sebesar 83%. Hasil tersebut menunjukkan bahwa model mampu mengklasifikasikan pasien yang memiliki penyakit jantung maupun pasien sehat dengan cukup baik dan seimbang. Indikator keberhasilan kegiatan ditunjukkan dari tingginya nilai akurasi model serta kecilnya tingkat kesalahan klasifikasi yang terjadi. Berikut merupakan gambar hasil evaluasi model :




Gambar 2. confusion matrix

Interpretasi terhadap confusion matrix menunjukkan bahwa algoritma Random Forest telah bekerja secara optimal dalam mengidentifikasi kondisi kesehatan pasien. Secara mendetail, model berhasil melakukan klasifikasi yang tepat pada 24 data sebagai True Negative (pasien sehat yang terdeteksi akurat) dan 27 data sebagai True Positive (pasien sakit yang terdeteksi akurat). Sebaliknya, ditemukan adanya deviasi berupa 5 kasus False Positive serta 5 kasus False Negative. Dominasi prediksi yang tepat dibandingkan angka kesalahan ini mencerminkan bahwa model memiliki stabilitas performa yang cukup seimbang.

Meskipun secara statistik hasilnya memuaskan dengan total 51 prediksi benar dari 61 data uji, keberadaan nilai *False Negative* tetap menjadi poin kritis dalam evaluasi ini. Dalam ranah medis, kegagalan sistem dalam mendeteksi keberadaan penyakit pada pasien yang sebenarnya sakit membawa risiko klinis yang serius. Oleh karena itu, walaupun Random Forest terbukti handal dalam memetakan pola penyakit jantung pada dataset ini, minimalisasi kesalahan prediksi pada kategori pasien positif tetap menjadi prioritas utama. Secara umum, tingkat kesalahan yang relatif kecil dan merata di kedua kelas target menegaskan bahwa model ini cukup kompeten untuk digunakan dalam analisis prediktif.

### Hasil Analisis Feature Importance

Berikut merupakan hasil analisis Feature Importance :



Gambar 3. feature importance pada prediksi penyakit jantung

Berdasarkan hasil analisis, fitur yang memiliki pengaruh terbesar adalah:

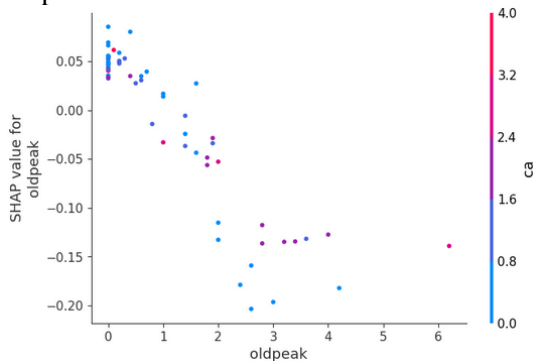
1. oldpeak
2. thalach
3. ca
4. cp
5. thal

Berdasarkan hasil feature importance, variabel oldpeak dan thalach merupakan faktor dominan dalam menentukan prediksi penyakit jantung, yang menunjukkan kesesuaian dengan pengetahuan medis.

### Hasil Implementasi Explainable Artificial Intelligence (XAI)

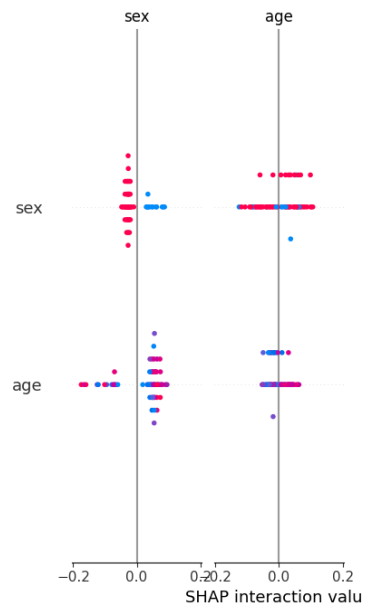
Melalui visualisasi SHAP, diketahui bahwa beberapa fitur seperti oldpeak,

thalach, dan ca memiliki kontribusi besar terhadap hasil prediksi penyakit jantung. Berikut merupakan gambar SHAP pada oldpeak



Gambar 4. Hasil nilai SHAP pada oldpeak

Berdasarkan hasil visualisasi SHAP dependence plot pada fitur oldpeak, terlihat bahwa fitur ini memiliki pengaruh yang cukup besar terhadap prediksi penyakit jantung. Nilai SHAP cenderung menurun seiring meningkatnya nilai oldpeak. Hal ini menunjukkan bahwa perubahan nilai oldpeak memberikan kontribusi yang signifikan terhadap keputusan model dalam memprediksi penyakit jantung. Pada nilai oldpeak yang rendah, nilai SHAP cenderung positif, sedangkan pada nilai oldpeak yang lebih tinggi nilai SHAP menjadi negatif dengan kontribusi yang semakin besar. Selain itu, warna pada titik menunjukkan adanya interaksi dengan fitur ca (jumlah pembuluh darah utama). Beberapa titik dengan nilai ca yang lebih tinggi menunjukkan pengaruh tambahan terhadap hasil prediksi model. Hasil ini menunjukkan bahwa model Random Forest mampu mengenali hubungan antara kondisi depresi segmen ST (oldpeak) dengan faktor pembuluh darah dalam menentukan risiko penyakit jantung. Selain menganalisis pengaruh fitur oldpeak terhadap prediksi penyakit jantung, penelitian ini juga melakukan analisis interaksi antar fitur menggunakan metode SHAP. Analisis tersebut dilakukan untuk mengetahui bagaimana hubungan antara fitur sex dan age dalam memengaruhi hasil prediksi model random Forest. Berikut merupakan gambar SHAP sex dan age.



Gambar 5. SHAP sex dan age

Berdasarkan hasil visualisasi SHAP interaction plot antara fitur sex dan age, terlihat bahwa kedua fitur memiliki hubungan interaksi dalam memengaruhi prediksi penyakit jantung. Nilai SHAP interaction menunjukkan bahwa kontribusi fitur usia dan jenis kelamin tidak berdiri sendiri, melainkan saling memengaruhi dalam proses pengambilan keputusan model Random Forest. Pada beberapa data terlihat bahwa usia yang lebih tinggi memberikan pengaruh yang lebih besar terhadap prediksi, terutama pada kelompok jenis kelamin tertentu. Sebaliknya, terdapat juga beberapa data dengan kontribusi yang lebih kecil atau mendekati nol, yang menunjukkan bahwa pengaruh kedua fitur dapat berbeda pada setiap individu. Hasil ini menunjukkan bahwa model mampu mengenali pola hubungan yang kompleks antara usia dan jenis kelamin dalam menentukan risiko penyakit jantung. Dengan adanya analisis SHAP interaction, proses interpretasi model menjadi lebih transparan sehingga faktor-faktor yang memengaruhi hasil prediksi dapat dipahami dengan lebih baik.

## PENUTUP

Peneliti membuktikan efektivitas algoritma Random Forest dalam memprediksi penyakit jantung dengan capaian akurasi sebesar 83 persen. Hasil evaluasi mengonfirmasi kemampuan model dalam

mengklasifikasikan data secara akurat dan proporsional bagi kelompok pasien sehat maupun penderita gangguan jantung.

Integrasi metode SHAP dalam kerangka Explainable Artificial Intelligence (XAI) sukses menguraikan logika di balik prediksi model tersebut secara mendalam. Temuan analisis menempatkan variabel oldpeak, thalach, serta ca sebagai indikator yang paling dominan dalam menentukan estimasi kondisi jantung pasien.

Selain itu, metode SHAP turut memetakan korelasi dinamis antarvariabel, termasuk keterkaitan antara usia dan jenis kelamin yang memengaruhi luaran prediksi secara signifikan. Studi ini mempertegas bahwa implementasi XAI memperkuat aspek transparansi sistem machine learning guna mengeliminasi sifat black-box dalam pengambilan keputusan medis.

Melalui pendekatan ini, riset menghasilkan model prediksi yang tidak hanya unggul secara performa, tetapi juga menawarkan kejelasan interpretatif yang sangat krusial bagi pengembangan teknologi di sektor kesehatan..

#### DAFTAR PUSTAKA

- [1] O. Ozdemir and T. O. Fatunmbi, "Page | 32 Explainable AI (XAI) in Healthcare: Bridging the Gap between Accuracy and Interpretability," *J. Sci. Technol. Eng. Res.*, vol. 2, no. 1, pp. 32–45, 2024.
- [2] P. Gohel, P. Singh, and M. Mohanty, "Explainable AI: current status and future directions," pp. 1–16, 2017.
- [3] H. Li, S. Vulova, A. D. Rocha, and B. Kleinschmit, "Spatio-temporal feature attribution of European summer wildfires with Explainable Artificial Intelligence (XAI)," *Sci. Total Environ.*, vol. 916, p. 170330, 2024, doi: <https://doi.org/10.1016/j.scitotenv.2024.170330>.
- [4] A. Rachha and M. Seyam, "Explainable AI In Education: Current Trends, Challenges, And Opportunities," in *SoutheastCon 2023*, 2023, pp. 232–239. doi: 10.1109/SoutheastCon51012.2023.10115140.
- [5] G. Joshi *et al.*, "Explainable Misinformation Detection Across Multiple Social Media Platforms," *IEEE Access*, vol. 11, pp. 23634–23646, 2023, doi: 10.1109/ACCESS.2023.3251892.
- [6] Z. Zhang, H. Al Hamadi, E. Damiani, C. Y. Yeun, and F. Taher, "Explainable Artificial Intelligence Applications in Cyber Security: State-of-the-Art in Research," *IEEE Access*, vol. 10, pp. 93104–93139, 2022, doi: 10.1109/ACCESS.2022.3204051.
- [7] R. Soundararajan and V. M. Shenbagaraman, "Enhancing Financial Decision-Making Through Explainable AI And Blockchain Integration: Improving Transparency And Trust In Predictive Models," *Educ. Adm. Theory Pract.*, vol. 30, no. 4, pp. 9341–9351, 2024, doi: 10.53555/kuey.v30i4.3672.
- [8] T. Hulsen, "Explainable Artificial Intelligence ( XAI ): Concepts and Challenges in Healthcare," *MDPI*, vol. 4, no. 3, pp. 652–666, 2023.
- [9] A. Šećkanović *et al.*, "Review of Artificial Intelligence Application in Cardiology," in *2020 9th Mediterranean Conference on Embedded Computing (MECO)*, 2020, pp. 8–11.
- [10] J. Karo-karo, A. R. Syakir, Sumanto, I. Budiawan, R. Pakpahan, and A. Christian, "Heart Disease Prediction Using Machine Learning Algorithms Based on Health Indicators with Random Forest," *J. Ilm. Sist. Inf.*, vol. 5, no. 1, pp. 84–95, 2026.
- [11] A. Rahmada and E. R. Susanto, "Peningkatan Akurasi Prediksi Penyakit Jantung dengan Teknik SMOTEENN pada Algoritma Random Forest Improving Heart Disease Prediction Accuracy with SMOTEENN Technique on Random Forest Algorithm," *J. Pendidik. dan Teknol. Indones.*, vol. 4, no. 12, pp. 795–803, 2024.
- [12] M. C. Arta, N. Anwar, Y. A. Putri, and M. Asroll, "Implementasi Prediksi Penyakit Jantung Menggunakan Data Mining Untuk Dunia Kesehatan Pre-processing," vol. 10, no. 01, pp. 42–48, 2024.

- 
- [13] M. A. Talukder, A. S. Talaat, M. Kazi, and A. Khraisat, "XAI-HD: an explainable artificial intelligence framework for heart disease detection," *Artif. Intell. Rev.*, vol. 58, no. 12, p. 385, 2025, doi: 10.1007/s10462-025-11385-6.
- [14] S. Santhosh, K. Chadaga, R. V. Arjunan, and S. D'Souza, "Cardiac Clarity: Harnessing Machine Learning for Accurate Heart-Disease Prediction," *IEEE Access*, vol. 13, pp. 97529–97544, 2025, doi: 10.1109/ACCESS.2025.3573760.
- [15] N. K. Al-waeli, S. A. Alhamami, and A. M. A. Almasabi, "Early Detection of Heart Disease using a Random Forest Classifier on the UCI Heart Disease Dataset," *Int. J. Comput. Appl.*, vol. 187, no. 67, pp. 29–33, 2025.
- [16] S. Dhanka and S. Maini, "Random Forest for Heart Disease Detection: A Classification Approach," in *2021 IEEE 2nd International Conference On Electrical Power and Energy Systems (ICEPES)*, 2021, pp. 1–3. doi: 10.1109/ICEPES52894.2021.9699506.
- [17] M. B, A. V. P. M. B, J. Chellam, A. B, R. R. M, and M. V, "Explainable AI for Cardiovascular Health: A SHAP-Based Framework," in *2025 International Conference on Pervasive Computational Technologies (ICPCT)*, 2025, pp. 353–358. doi: 10.1109/ICPCT64145.2025.10940403.