

Explainable Machine Learning untuk Prediksi Risiko Penyakit Jantung Menggunakan Random Forest dan Analisis SHAP

¹Luthfia Nurma Hapsari, ²Ilham Fannani, ³Yenny Rahmawati, ⁴Ahmad Muhariya
^{1,2,3,4}Universitas Tiga Serangkai
Surakarta, Indonesia

¹luthfianh@tsu.ac.id, ²ilhamfannani@tsu.ac.id, ³yennyrahmawati@tsu.ac.id,
⁴ahmadmuhariya@tsu.ac.id

*Penulis Korespondensi

Diajukan : 28/12/2025
Diterima : 07/01/2026
Dipublikasi : 09/01/2026

ABSTRAK

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia, sehingga diperlukan metode yang efektif untuk memprediksi risiko penyakit tersebut secara dini. Penelitian ini bertujuan untuk menerapkan pendekatan machine learning berbasis Random Forest dalam memprediksi risiko penyakit jantung menggunakan data klinis pasien, serta meningkatkan transparansi model melalui pendekatan explainable machine learning menggunakan SHAP. Dataset yang digunakan merupakan data penyakit jantung publik yang berisi fitur-fitur klinis seperti usia, jenis kelamin, tekanan darah, kadar kolesterol, dan denyut jantung maksimum. Model Random Forest dilatih dan dievaluasi menggunakan data uji dengan metrik akurasi, precision, recall, dan F1-score. Hasil evaluasi menunjukkan bahwa model Random Forest memperoleh nilai akurasi sebesar 0,80 dan F1-score tertimbang sebesar 0,80. Selain itu, nilai recall sebesar 0,80 dan precision 0,82 pada kelas penyakit jantung menunjukkan bahwa model cukup efektif dalam mendeteksi pasien yang berisiko. Analisis interpretabilitas menggunakan SHAP menunjukkan bahwa fitur chest pain type, thalassemia, dan jumlah pembuluh darah utama merupakan fitur yang memiliki kontribusi paling besar terhadap prediksi risiko penyakit jantung. Hasil penelitian ini menunjukkan bahwa Random Forest dengan pendekatan explainable machine learning berbasis SHAP mampu memberikan prediksi yang cukup baik serta interpretasi model yang lebih transparan, sehingga berpotensi digunakan sebagai alat bantu analisis berbasis data pada prediksi risiko penyakit jantung.

Kata kunci: *explainable machine learning, machine learning, penyakit jantung, Random Forest, SHAP*

I. PENDAHULUAN

Penyakit kardiovaskular merupakan salah satu penyebab utama kematian di dunia dan menjadi tantangan besar dalam sistem pelayanan kesehatan, sehingga deteksi dan penanganan dini menjadi sangat penting (Yu et al., 2025). Salah satu kelompok utama dalam penyakit kardiovaskular adalah penyakit jantung, yang memerlukan identifikasi risiko secara dini berbasis data klinis pasien.

Pemanfaatan data klinis untuk mendukung prediksi risiko penyakit jantung telah banyak dikembangkan menggunakan pendekatan machine learning, terutama karena kemampuannya dalam menangkap pola kompleks pada data tabular yang sulit dimodelkan secara konvensional (BANERJEE & PAÇAL, 2025).

Berbagai algoritma *machine learning* telah diterapkan pada data klinis, seperti *Logistic*

Regression, Decision Tree, dan Random Forest, yang menunjukkan kinerja kompetitif dalam berbagai tugas prediksi Kesehatan (Ahiduzzaman & Hasan, 2025; Winanti, Martiyarningsih, Soemedhy, & Athiyah, 2023). Di antara algoritma tersebut, *Random Forest* dikenal memiliki performa yang stabil, mampu menangani hubungan non-linear, serta relatif tahan terhadap *overfitting* pada data klinis (Ratnasari, Jurnaidi Wahidin, Eko Setiawan, & Bintoro, 2024). Meskipun demikian, model machine learning seperti Random Forest umumnya bersifat *black-box*, sehingga sulit dijelaskan bagaimana suatu prediksi dihasilkan. Keterbatasan interpretabilitas ini menjadi tantangan penting dalam konteks pengambilan keputusan klinis, karena tenaga medis membutuhkan pemahaman yang jelas terhadap faktor-faktor yang memengaruhi hasil prediksi (Kabir, Hossain, & Andersson, 2025). Oleh karena itu, pendekatan *explainable machine learning* dikembangkan untuk meningkatkan transparansi dan kepercayaan terhadap model prediktif.

Salah satu metode explainability yang banyak digunakan adalah SHAP (SHapley Additive exPlanations), yang mampu menjelaskan kontribusi masing-masing fitur terhadap hasil prediksi model secara konsisten dan aditif (Kabir et al., 2025). Dalam konteks prediksi penyakit jantung, SHAP berpotensi memberikan wawasan mengenai faktor-faktor klinis yang berpengaruh secara global terhadap keputusan model.

Berdasarkan latar belakang tersebut, penelitian ini menerapkan model Random Forest untuk prediksi risiko penyakit jantung pada dataset klinis publik, serta mengombinasikannya dengan evaluasi kinerja model dan analisis interpretabilitas global menggunakan SHAP. Novelty penelitian ini terletak pada integrasi evaluasi performa klasifikasi dengan analisis SHAP global untuk mengidentifikasi kontribusi fitur klinis utama pada dataset penyakit jantung yang digunakan, sehingga model tidak hanya dinilai dari akurasi prediksi, tetapi juga dari transparansi dan kejelasan pengambilan keputusannya.

Secara teoretis, penelitian ini memberikan kontribusi dalam penerapan explainable machine learning pada model Random Forest untuk data klinis tabular. Secara praktis, hasil penelitian diharapkan dapat menjadi dasar analisis berbasis data yang lebih transparan dalam mendukung pemahaman faktor risiko penyakit jantung, serta berpotensi digunakan sebagai alat bantu dalam pengambilan keputusan klinis.

II. STUDI LITERATUR

1. Machine Learning untuk Prediksi Penyakit Jantung

Machine learning merupakan cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma yang mampu mempelajari pola dari data dan menghasilkan prediksi atau keputusan tanpa perlu diprogram secara eksplisit (Ahiduzzaman & Hasan, 2025). Dalam bidang kesehatan, machine learning telah banyak dimanfaatkan untuk membantu analisis data medis, termasuk diagnosis penyakit, prediksi risiko, serta pengambilan keputusan klinis berbasis data (Nayyar, Gadhavi, & Zaman, 2021). Salah satu aplikasi penting machine learning dalam kesehatan adalah prediksi penyakit jantung, mengingat penyakit jantung masih menjadi salah satu penyebab utama kematian di dunia (Santoso et al., 2024).

Prediksi risiko penyakit jantung umumnya memanfaatkan data klinis pasien yang bersifat tabular, seperti usia, jenis kelamin, tekanan darah, kadar kolesterol, kadar gula darah, serta hasil pemeriksaan elektrokardiografi (Kailasanathan et al., 2025). Data-data tersebut mengandung pola tertentu yang dapat digunakan untuk membedakan pasien yang berisiko dan tidak berisiko terhadap penyakit jantung. Dengan menggunakan pendekatan machine learning, proses analisis data dapat dilakukan secara lebih sistematis dan objektif, sehingga berpotensi membantu tenaga medis dalam pengambilan keputusan.

Namun demikian, penggunaan machine learning dalam konteks kesehatan tidak hanya menuntut performa prediksi yang baik, tetapi juga membutuhkan kejelasan dalam interpretasi hasil. Oleh karena itu, pemilihan algoritma yang sesuai dan dapat dijelaskan menjadi aspek penting dalam penelitian prediksi penyakit jantung berbasis machine learning.

2. Random Forest

Random Forest merupakan salah satu algoritma ensemble learning yang menggabungkan sejumlah decision tree untuk meningkatkan performa prediksi. Algoritma ini bekerja dengan membangun banyak pohon keputusan menggunakan subset data dan subset fitur yang dipilih secara acak. Setiap pohon menghasilkan prediksi, dan hasil akhir ditentukan berdasarkan mekanisme voting mayoritas pada kasus klasifikasi. Mekanisme ini menjadikan Random Forest memiliki performa yang baik untuk klasifikasi aneka data termasuk dataset terkait penyakit (Akhmad Pandhu Wijaya, 2025; Winanti et al., 2023).

Keunggulan utama Random Forest terletak pada kemampuannya dalam menangani data tabular, mengurangi risiko overfitting, serta menangkap hubungan non-linear antar fitur (Barreñada, Dhiman, Timmerman, Boulesteix, & Van Calster, 2024). Dibandingkan dengan algoritma berbasis single tree, Random Forest cenderung lebih stabil dan robust terhadap noise pada data. Selain itu, Random Forest tidak memerlukan asumsi distribusi data tertentu, sehingga cocok digunakan pada data klinis yang umumnya bersifat heterogen.

Dalam konteks prediksi penyakit kardiovaskular, Random Forest banyak digunakan karena mampu memberikan performa yang baik meskipun ukuran dataset relatif terbatas (Sumwiza, Twizere, Rushingabigwi, Bakunzibake, & Bamurigire, 2023). Oleh sebab itu, algoritma ini dipilih sebagai model utama dalam penelitian ini untuk memprediksi risiko penyakit jantung berdasarkan data klinis pasien.

3. Explainable Machine Learning

Meskipun algoritma machine learning seperti Random Forest mampu memberikan performa prediksi yang baik, model tersebut sering dianggap sebagai black-box sulit dijelaskan secara langsung (Kabir et al., 2025). Dalam bidang kesehatan, keterbatasan interpretabilitas menjadi tantangan penting, karena hasil prediksi perlu dipahami oleh tenaga medis agar dapat digunakan sebagai dasar pengambilan keputusan.

Explainable machine learning merupakan pendekatan yang bertujuan untuk meningkatkan transparansi dan interpretabilitas model machine learning (Belle & Papantonis, 2021). Pendekatan ini berfokus pada penyediaan penjelasan mengenai bagaimana dan mengapa suatu model menghasilkan prediksi tertentu. Dengan adanya penjelasan tersebut, kepercayaan terhadap model dapat meningkat, serta potensi kesalahan interpretasi dapat diminimalkan.

Dalam penelitian prediksi penyakit jantung, explainable machine learning berperan penting untuk mengidentifikasi faktor-faktor klinis yang berkontribusi terhadap risiko penyakit. Dengan demikian, model tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai sarana untuk memperoleh wawasan tambahan dari data.

4. SHAP (SHapley Additive exPlanations)

SHAP merupakan salah satu metode explainability yang populer dan banyak digunakan dalam analisis model machine learning (Nohara, Matsumoto, Soejima, & Nakashima, 2022). Metode ini didasarkan pada konsep nilai Shapley dari teori permainan, yang digunakan untuk menghitung kontribusi masing-masing fitur terhadap hasil prediksi model. SHAP menyediakan pendekatan yang konsisten dan aditif dalam menjelaskan prediksi, sehingga hasil interpretasi menjadi lebih reliabel (Ogami et al., 2021).

SHAP dapat diterapkan pada berbagai jenis model, termasuk model berbasis pohon seperti Random Forest (Castronuovo, Favia, Telesca, & Vammacigno, 2023). Metode ini mampu memberikan penjelasan baik pada tingkat global, yaitu untuk melihat fitur-fitur yang paling berpengaruh secara keseluruhan, maupun pada tingkat lokal, yaitu untuk menjelaskan prediksi pada individu tertentu. Dalam penelitian ini, SHAP digunakan untuk mengidentifikasi fitur klinis yang memiliki pengaruh signifikan terhadap prediksi risiko penyakit jantung yang dihasilkan oleh model Random Forest.

5. Evaluasi Kinerja Model

Evaluasi kinerja model klasifikasi dilakukan untuk menilai kemampuan model dalam menghasilkan prediksi yang akurat dan andal. Beberapa metrik evaluasi yang umum digunakan dalam permasalahan klasifikasi antara lain akurasi, precision, recall, dan F1-score (Sujon, Hassan,

Choi, & Samad, 2025). Akurasi mengukur proporsi prediksi yang benar terhadap seluruh data, sedangkan precision dan recall digunakan untuk mengevaluasi kualitas prediksi pada masing-masing kelas.

F1-score merupakan metrik yang menggabungkan precision dan recall, sehingga memberikan gambaran kinerja model yang lebih seimbang, terutama pada data dengan distribusi kelas yang tidak seimbang (Naidu, Zuva, & Sibanda, 2023). Dalam penelitian ini, metrik akurasi dan F1-score digunakan untuk mengevaluasi performa model Random Forest dalam memprediksi risiko penyakit jantung.

III. METODE

1. Dataset

Penelitian ini menggunakan dataset penyakit jantung yang bersifat publik dan tersedia dalam format CSV. Dataset terdiri dari 303 data pasien dengan 13 fitur klinis dan satu variabel target. Seluruh fitur bersifat numerik dan merepresentasikan atribut klinis yang umum digunakan dalam analisis penyakit jantung, seperti usia, jenis kelamin, tipe nyeri dada, tekanan darah, kadar kolesterol, denyut jantung maksimum, serta parameter klinis lainnya.

Variabel target bersifat biner, dengan nilai 0 menunjukkan tidak adanya penyakit jantung dan nilai 1 menunjukkan adanya penyakit jantung. Berdasarkan pemeriksaan awal, dataset tidak mengandung nilai hilang (missing value), sehingga tidak diperlukan proses imputasi. Distribusi kelas target relatif seimbang, dengan 165 data pada kelas penyakit jantung dan 138 data pada kelas tanpa penyakit, sehingga potensi ketidakseimbangan kelas ditangani melalui konfigurasi parameter pada model klasifikasi.

Deskripsi lengkap setiap fitur klinis yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Deskripsi Fitur pada Dataset Penyakit Jantung

No	Nama Fitur	Deskripsi Singkat
1	age	Usia pasien
2	sex	Jenis kelamin pasien (1 = laki-laki, 0 = perempuan)
3	cp	Tipe nyeri dada (chest pain type)
4	trestbps	Tekanan darah saat istirahat
5	chol	Kadar kolesterol serum
6	fbs	Kadar gula darah puasa
7	restecg	Hasil elektrokardiografi saat istirahat
8	thalach	Denyut jantung maksimum yang dicapai
9	exang	Angina akibat aktivitas fisik
10	oldpeak	Depresi segmen ST akibat olahraga
11	slope	Kemiringan segmen ST
12	ca	Jumlah pembuluh darah utama
13	thal	Kondisi thalassemia
14	target	Label penyakit jantung (1 = ada, 0 = tidak ada)

2. Tahapan Penelitian

Tahapan penelitian yang dilakukan dapat dirangkum sebagai berikut:

1. Pengumpulan dan pemuatan dataset
2. Pra-pemrosesan data dan pemisahan data menjadi data latih dan data uji
3. Pelatihan model Random Forest
4. Evaluasi kinerja model
5. Analisis interpretabilitas model menggunakan SHAP

3. Pra-pemrosesan Data

Pada tahap pra-pemrosesan, data dipisahkan menjadi fitur dan variabel target. Selanjutnya, dataset dibagi menjadi data latih dan data uji menggunakan metode hold-out split dengan proporsi 80% data latih dan 20% data uji, serta mempertahankan distribusi kelas (stratified split). Pendekatan ini bertujuan untuk memastikan bahwa data uji merepresentasikan distribusi kelas yang serupa dengan data latih.

Algoritma Random Forest tidak memerlukan normalisasi atau penskalaan fitur karena tidak sensitif terhadap perbedaan skala antar fitur (Vadapalli, n.d.). Oleh karena itu, data digunakan dalam bentuk aslinya untuk proses pelatihan dan pengujian model.

4. Model Random Forest

Model utama yang digunakan dalam penelitian ini adalah Random Forest untuk melakukan klasifikasi risiko penyakit jantung. Random Forest dibangun menggunakan sejumlah pohon keputusan dengan parameter jumlah pohon (number of estimators) yang ditentukan secara empiris (Vadapalli, n.d.). Model dikonfigurasi dengan jumlah pohon ($n_estimators$) sebesar 200, yang dipilih secara empiris untuk meningkatkan stabilitas prediksi. Parameter `class_weight` diset ke *balanced* untuk mengakomodasi distribusi kelas target yang tidak sepenuhnya seimbang, sehingga kesalahan klasifikasi pada kelas minoritas dapat diminimalkan. Selain itu, parameter `random_state` sebesar 42 digunakan untuk memastikan reproduktibilitas hasil eksperimen. Model ini dilatih menggunakan data latih dan digunakan untuk menghasilkan prediksi pada data uji.

Random Forest dipilih karena kemampuannya dalam menangani data tabular, menangkap hubungan non-linear antar fitur, serta memberikan performa yang stabil pada dataset berukuran kecil hingga menengah (Barreñada et al., 2024).

5. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan menggunakan beberapa metrik evaluasi klasifikasi, yaitu akurasi, precision, recall, dan F1-score. Akurasi digunakan untuk mengukur proporsi prediksi yang benar terhadap keseluruhan data uji, sedangkan precision, recall, dan F1-score digunakan untuk mengevaluasi kualitas prediksi pada masing-masing kelas.

Penggunaan metrik F1-score bertujuan untuk memberikan gambaran kinerja model yang lebih seimbang, khususnya pada permasalahan klasifikasi dengan distribusi kelas yang tidak sepenuhnya seimbang (Sujon et al., 2025).

Hasil evaluasi digunakan untuk menilai kemampuan model Random Forest dalam memprediksi risiko penyakit jantung berdasarkan data klinis yang digunakan.

6. Analisis Interpretabilitas Model dengan SHAP

Untuk meningkatkan interpretabilitas model, penelitian ini menerapkan metode SHAP (SHapley Additive exPlanations). SHAP digunakan untuk menganalisis kontribusi masing-masing fitur terhadap prediksi model Random Forest berdasarkan pendekatan teori permainan, sehingga memberikan penjelasan yang konsisten dan aditif (Castronuovo et al., 2023). Metode ini menghitung nilai kontribusi fitur berdasarkan pendekatan teori permainan, sehingga dapat memberikan penjelasan yang konsisten dan aditif.

Analisis SHAP dilakukan secara global menggunakan *summary plot* berbentuk diagram batang (*bar plot*) untuk mengidentifikasi fitur-fitur klinis yang memiliki pengaruh paling besar terhadap prediksi risiko penyakit jantung.

IV. HASIL DAN PEMBAHASAN

1. Hasil Evaluasi Kinerja Model

Model Random Forest dilatih menggunakan data latih dan dievaluasi pada data uji untuk memprediksi risiko penyakit jantung berdasarkan fitur-fitur klinis yang tersedia. Evaluasi kinerja dilakukan menggunakan beberapa metrik, yaitu accuracy, precision, recall, dan F1-score, guna memperoleh gambaran yang komprehensif mengenai performa model dalam melakukan klasifikasi.

Hasil evaluasi kinerja model Random Forest ditunjukkan pada Tabel 1. Berdasarkan hasil tersebut, model Random Forest memperoleh nilai akurasi sebesar 0,80, yang menunjukkan bahwa model mampu mengklasifikasikan data uji dengan tingkat ketepatan yang cukup baik. Nilai F1-score tertimbang (weighted average) sebesar 0,80 juga menunjukkan keseimbangan yang baik antara precision dan recall pada kedua kelas.

Tabel 2. Hasil Evaluasi Kinerja Model Random Forest

Metrik	Nilai
Accuracy	0,80
Precision (weighted avg)	0,82
Recall (weighted avg)	0,80
F1-score (weighted avg)	0,80

Berdasarkan hasil klasifikasi per kelas, model menunjukkan nilai recall yang tinggi pada kelas penyakit jantung (kelas 1) sebesar 0,94, yang mengindikasikan bahwa sebagian besar data pasien dengan penyakit jantung berhasil terdeteksi oleh model. Sementara itu, nilai precision pada kelas tanpa penyakit jantung (kelas 0) mencapai 0,90, yang menunjukkan bahwa prediksi model pada kelas tersebut relatif akurat.

Perbedaan nilai precision dan recall antar kelas menunjukkan adanya trade-off yang umum terjadi pada permasalahan klasifikasi data medis. Namun demikian, nilai F1-score yang diperoleh menunjukkan bahwa model Random Forest mampu memberikan performa yang cukup seimbang dalam membedakan pasien dengan dan tanpa risiko penyakit jantung.

Hasil evaluasi ini mengindikasikan bahwa Random Forest sesuai digunakan untuk permasalahan klasifikasi risiko penyakit jantung berbasis data klinis tabular. Selain itu, performa model yang stabil menunjukkan bahwa Random Forest mampu menangani kompleksitas hubungan antar fitur tanpa mengalami overfitting yang signifikan pada dataset yang digunakan.


2. Analisis Interpretabilitas Model Menggunakan SHAP

Selain mengevaluasi kinerja prediksi, penelitian ini juga menganalisis interpretabilitas model Random Forest menggunakan metode SHAP. Analisis SHAP bertujuan untuk mengidentifikasi kontribusi masing-masing fitur klinis terhadap prediksi risiko penyakit jantung yang dihasilkan oleh model.

Gambar 1 menampilkan SHAP summary plot dalam bentuk diagram batang yang menunjukkan tingkat kepentingan fitur secara global berdasarkan nilai rata-rata absolut SHAP (mean |SHAP value|). Nilai tersebut merepresentasikan besarnya pengaruh masing-masing fitur terhadap keluaran model tanpa memperhatikan arah pengaruhnya.

Berdasarkan Gambar 1, fitur chest pain type (cp) memiliki kontribusi paling besar terhadap prediksi model, diikuti oleh fitur thalassemia (thal) dan jumlah pembuluh darah utama (ca). Selanjutnya, fitur denyut jantung maksimum (thalach) dan depresi ST akibat olahraga (oldpeak) juga menunjukkan pengaruh yang cukup signifikan. Fitur lain seperti exercise induced angina (exang), kemiringan segmen ST (slope), serta jenis kelamin (sex) memiliki kontribusi menengah terhadap prediksi model.

Sementara itu, fitur kadar kolesterol (chol) dan usia (age) menunjukkan kontribusi yang relatif lebih kecil dibandingkan fitur-fitur utama, namun tetap memberikan pengaruh terhadap hasil prediksi. Beberapa fitur seperti hasil elektrokardiografi saat istirahat (restecg), tekanan darah istirahat (resttbps), dan kadar gula darah puasa (fbs) memiliki kontribusi yang paling rendah terhadap prediksi risiko penyakit jantung pada dataset yang digunakan.



Gambar 1. SHAP Summary Plot (Bar Plot) Model Random Forest

3. Diskusi

Hasil evaluasi kinerja menunjukkan bahwa model Random Forest mampu memberikan performa prediksi yang cukup baik dalam mengklasifikasikan risiko penyakit jantung berdasarkan data klinis, dengan nilai akurasi dan F1-score sebesar 0,80. Hasil ini sejalan dengan berbagai penelitian sebelumnya yang menerapkan Random Forest pada permasalahan prediksi penyakit jantung dan melaporkan performa yang kompetitif pada berbagai dataset dan skenario evaluasi (Ratnasari et al., 2024; Sumwiza et al., 2023). Perbedaan nilai kinerja yang dilaporkan dalam penelitian-penelitian tersebut menunjukkan bahwa performa model sangat dipengaruhi oleh karakteristik dataset dan pendekatan evaluasi yang digunakan.

Dibandingkan dengan pendekatan machine learning lain yang umum digunakan pada permasalahan serupa, seperti Logistic Regression dan Decision Tree, Random Forest dilaporkan memiliki keunggulan dalam menangkap hubungan non-linear antar fitur klinis serta lebih tahan terhadap overfitting pada dataset berukuran terbatas (Ahiduzzaman & Hasan, 2025; Barreñada et al., 2024). Dengan demikian, hasil penelitian ini memperkuat temuan sebelumnya bahwa Random Forest merupakan pilihan yang relevan untuk analisis prediksi penyakit jantung.

Selain aspek kinerja, penelitian ini menekankan pentingnya interpretabilitas model melalui analisis SHAP. Hasil SHAP global menunjukkan bahwa fitur *chest pain type* (cp), *thalassemia* (thal), dan jumlah pembuluh darah utama (ca) merupakan fitur yang paling dominan dalam memengaruhi prediksi risiko penyakit jantung pada dataset yang digunakan. Temuan ini menunjukkan bahwa model memanfaatkan fitur-fitur klinis yang

relevan secara medis, khususnya yang berkaitan dengan karakteristik nyeri dada dan kondisi pembuluh darah.

Hasil ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa analisis SHAP mampu mengidentifikasi fitur-fitur klinis penting dalam prediksi penyakit kardiovaskular, meskipun jenis fitur dominan dapat berbeda bergantung pada karakteristik dataset dan konteks analisis yang digunakan (Yu et al., 2025). Selain itu, fitur seperti tipe nyeri dada, angina akibat aktivitas fisik, dan parameter klinis terkait jantung berperan penting dalam menjelaskan prediksi model pada tingkat individu, yang memperkuat peran SHAP sebagai alat interpretasi dalam konteks klinis (Kailasanathan et al., 2025).

Implikasi klinis dari hasil SHAP menunjukkan bahwa model cenderung memanfaatkan fitur-fitur yang secara medis memang relevan, seperti tipe nyeri dada, kapasitas pembuluh darah, dan respons jantung terhadap aktivitas fisik. Hal ini memberikan indikasi bahwa model tidak hanya menghasilkan prediksi berbasis pola statistik semata, tetapi juga mempertimbangkan informasi klinis yang bermakna. Fitur-fitur lain seperti denyut jantung maksimum (*thalach*) dan depresi segmen ST (*oldpeak*) juga menunjukkan kontribusi yang signifikan, yang sejalan dengan indikator umum dalam evaluasi fungsi jantung.

Meskipun demikian, penting untuk ditegaskan bahwa analisis SHAP dalam penelitian ini berfungsi sebagai alat bantu interpretasi model, bukan sebagai pengganti keputusan klinis. SHAP digunakan untuk memberikan transparansi terhadap cara model memanfaatkan fitur klinis dalam menghasilkan prediksi, sehingga hasilnya dapat lebih mudah dipahami oleh pengguna. Keputusan medis tetap harus didasarkan pada evaluasi klinis menyeluruh oleh tenaga kesehatan yang berkompeten.

Secara keseluruhan, kombinasi antara evaluasi kinerja model dan analisis interpretabilitas berbasis SHAP memberikan nilai tambah pada penelitian ini. Namun, keterbatasan penelitian tetap ada, terutama terkait penggunaan dataset publik dengan ukuran yang relatif terbatas. Oleh karena itu, validasi lebih lanjut menggunakan dataset yang lebih besar dan beragam diperlukan agar temuan dapat digeneralisasi secara lebih luas dalam konteks klinis yang nyata.

V. KESIMPULAN

Penelitian ini menerapkan pendekatan machine learning berbasis Random Forest untuk memprediksi risiko penyakit jantung menggunakan data klinis pasien. Berdasarkan hasil evaluasi kinerja, model Random Forest menunjukkan performa klasifikasi yang cukup baik dengan nilai akurasi sebesar 0,80 dan F1-score tertimbang sebesar 0,80, yang menunjukkan kemampuan model dalam membedakan pasien dengan dan tanpa risiko penyakit jantung secara relatif seimbang.

Selain aspek performa, penelitian ini memberikan kontribusi pada bidang machine learning kesehatan dan explainable artificial intelligence melalui integrasi evaluasi kinerja model dengan analisis interpretabilitas berbasis SHAP. Pendekatan ini memungkinkan pemahaman yang lebih transparan terhadap peran fitur-fitur klinis dalam proses prediksi, sehingga model tidak hanya berfungsi sebagai alat klasifikasi, tetapi juga sebagai sarana interpretasi berbasis data.

Dari sisi praktis, hasil penelitian ini dapat dimanfaatkan sebagai dasar pengembangan sistem prediksi risiko penyakit jantung berbasis data klinis yang lebih transparan dan mudah dipahami. Informasi mengenai fitur-fitur klinis dominan yang diperoleh dari analisis SHAP berpotensi membantu pengguna sistem dalam memahami faktor risiko utama yang dipertimbangkan oleh model, sehingga dapat mendukung proses analisis dan pengambilan keputusan berbasis data.

Keterbatasan penelitian ini terletak pada penggunaan dataset publik dengan ukuran yang relatif terbatas serta evaluasi model yang belum mencakup perbandingan langsung dengan algoritma machine learning lain.

Penelitian selanjutnya disarankan untuk menggunakan dataset dengan jumlah data yang lebih besar dan beragam, serta mengembangkan evaluasi model melalui perbandingan dengan algoritma lain dan penerapan metode explainable machine learning tambahan guna memperkaya analisis interpretabilitas.

VI. REFERENSI

- Ahiduzzaman, M., & Hasan, M. N. (2025). Interpretable machine learning for cardiovascular risk prediction: Insights from NHANES dietary and health data. *PLOS One*, *20*(11), e0335915. doi:10.1371/journal.pone.0335915
- Akhmad Pandhu Wijaya. (2025). Perbandingan Algoritma Klasifikasi Random Forest dengan Naïve Bayes Classifier pada Studi Penyakit Berdasarkan Pola Nutrisi. *REMIK: Riset Dan E-Jurnal Manajemen Informatika Komputer*, *9*(1).
- BANERJEE, T., & PAÇAL, İ. (2025). A systematic review of machine learning in heart disease prediction. *Turkish Journal of Biology*, *49*(5), 600–634. doi:10.55730/1300-0152.2766
- Barreñada, L., Dhiman, P., Timmerman, D., Boulesteix, A.-L., & Van Calster, B. (2024). Understanding overfitting in random forest for probability estimation: a visualization and simulation study. *Diagnostic and Prognostic Research*, *8*(1), 14. doi:10.1186/s41512-024-00177-1
- Belle, V., & Papantonis, I. (2021). Principles and Practice of Explainable Machine Learning. *Frontiers in Big Data*, *4*. doi:10.3389/fdata.2021.688969
- Castronuovo, G., Favia, G., Telesca, V., & Vammacigno, A. (2023). Analyzing the Interactions between Environmental Parameters and Cardiovascular Diseases Using Random Forest and SHAP Algorithms. *Reviews in Cardiovascular Medicine*, *24*(11). doi:10.31083/j.rcm2411330
- Kabir, S., Hossain, M. S., & Andersson, K. (2025). A Review of Explainable Artificial Intelligence from the Perspectives of Challenges and Opportunities. *Algorithms*, *18*(9), 556. doi:10.3390/a18090556
- Kailasanathan, N., Ezhilarasan, G., Selvarajan, S., Dhanaraj, R. K., Pamucar, D., & Shankar, N. (2025). Heart disease prediction with a feature-sensitized interpretable framework for the Internet of Medical Things sensors. *Frontiers in Digital Health*, *7*. doi:10.3389/fdgth.2025.1612915
- Naidu, G., Zuva, T., & Sibanda, E. M. (2023). A Review of Evaluation Metrics in Machine Learning Algorithms (pp. 15–25). doi:10.1007/978-3-031-35314-7_2
- Nayyar, A., Gadhavi, L., & Zaman, N. (2021). Machine learning in healthcare: review, opportunities and challenges. In *Machine Learning and the Internet of Medical Things in Healthcare* (pp. 23–45). Elsevier. doi:10.1016/B978-0-12-821229-5.00011-2
- Nohara, Y., Matsumoto, K., Soejima, H., & Nakashima, N. (2022). Explanation of machine learning models using shapley additive explanation and application for real data in hospital. *Computer Methods and Programs in Biomedicine*, *214*, 106584. doi:10.1016/j.cmpb.2021.106584
- Ogami, C., Tsuji, Y., Seki, H., Kawano, H., To, H., Matsumoto, Y., & Hosono, H. (2021). An artificial neural network–pharmacokinetic model and its interpretation using Shapley additive

explanations. *CPT: Pharmacometrics & Systems Pharmacology*, 10(7), 760–768. doi:10.1002/psp4.12643

- Ratnasari, Jurnaidi Wahidin, A., Eko Setiawan, A., & Bintoro, P. (2024). Machine Learning Untuk Klasifikasi Penyakit Jantung. *Aisyah Journal Of Informatics and Electrical Engineering (A.J.I.E.E)*, 6(1), 145–150. doi:10.30604/jti.v6i1.272
- Santoso, M., Al-Akbar, B., Nurjaya, H., Ramadhan, S. A., Rizky, N. A., & Fadillah, A. (2024). Klasifikasi Potensi Penyakit Jantung Menggunakan Algoritma C4.5. *Jurnal INSAN Journal of Information System Management Innovation*, 3(2), 96–103. doi:10.31294/jinsan.v3i2.3056
- Sujon, K. M., Hassan, R., Choi, K., & Samad, M. A. (2025). Accuracy, precision, recall, f1-score, or MCC? empirical evidence from advanced statistics, ML, and XAI for evaluating business predictive models. *Journal of Big Data*, 12(1), 268. doi:10.1186/s40537-025-01313-4
- Sumwiza, K., Twizere, C., Rushingabigwi, G., Bakunzibake, P., & Bamurigire, P. (2023). Enhanced cardiovascular disease prediction model using random forest algorithm. *Informatics in Medicine Unlocked*, 41, 101316. doi:10.1016/j.imu.2023.101316
- Vadapalli, P. (n.d.). *Random Forest Classifier: Overview, How Does it Work*. Pros & Cons.
- Winanti, N. A., Martiyaningsih, D. P., Soemedhy, C. A. A., & Athiyah, U. (2023). Analisis Klasifikasi Citra Kanker Kulit dengan Random Forest. *Remik*, 7(1), 506–515. doi:10.33395/remik.v7i1.12102
- Yu, L., Wu, J., Wu, X., Chen, C., Chen, Y., Fang, L., & Zheng, D. (2025). Interpretable machine learning model for cardiovascular disease risk prediction: a feature decomposition-based study. *BMC Public Health*, 25(1), 3639. doi:10.1186/s12889-025-24921-4