



Komparasi Kinerja Algoritma Random Forest dan Decision Tree dalam Klasifikasi Penyakit Jantung

M. Nejatullah Sidqi *¹, Rio²

^{1,2} Universitas PGRI Silampari, Lubuklinggau, Indonesia

E-mail : neja.sidqi97@gmail.com *

*Penulis Korespondensi

Received 8 May 2026; Revised 2 June 2026; Accepted 12 June 2026

Abstrak - Penyakit jantung masih menjadi penyakit yang merenggut banyak nyawa, sehingga sangat penting untuk menemukan cara yang lebih cepat dan akurat dalam mendiagnosisnya. Perkembangan pesat dalam pembelajaran mesin kini membuka peluang untuk memanfaatkan berbagai algoritma klasifikasi guna memprediksi penyakit jantung berbekal data medis pasien. Studi ini berupaya membandingkan efektivitas algoritma Decision Tree dan Random Forest dalam mengklasifikasikan penyakit jantung dengan memanfaatkan kumpulan data Penyakit Jantung. Tahapan penelitian mencakup pengumpulan data, pembersihan dan penataan data awal, penjelajahan data (EDA), pembagian data menjadi set pelatihan dan pengujian, pelatihan model, serta penilaian kinerja melalui Confusion Matrix dan perhitungan tingkat akurasi. Berdasarkan evaluasi, algoritma Decision Tree mencapai tingkat akurasi 93,44% pada data pelatihan dan 87,34% pada data pengujian. Analisis Confusion Matrix untuk model ini mencatat 123 kasus True Negative, 146 True Positive, 27 False Positive, dan 12 False Negative. Sementara itu, algoritma Random Forest tampil lebih superior dengan akurasi pelatihan 99,02% dan akurasi pengujian 97,73%. Confusion Matrix untuk Random Forest mencatat 147 True Negative, 154 True Positive, 3 False Positive, dan 4 False Negative. Temuan ini menunjukkan bahwa Random Forest menawarkan akurasi yang lebih baik dan mengurangi kesalahan prediksi dibandingkan dengan Decision Tree. Hal ini mengindikasikan bahwa Random Forest lebih handal dalam mengidentifikasi pola data yang berkaitan dengan penyakit jantung dan lebih baik dalam menggeneralisasi hasilnya. Dengan demikian, algoritma Random Forest direkomendasikan sebagai pendekatan yang lebih efektif untuk klasifikasi penyakit jantung karena kemampuannya memberikan prediksi yang lebih akurat dan stabil.

Kata Kunci: Machine Learning, Decision Tree, Random Forest, Penyakit Jantung, Klasifikasi.

Abstract - Heart disease remains a life-threatening condition, making it crucial to find faster and more accurate methods for diagnosing it. Rapid advances in machine learning now offer the opportunity to utilize various classification algorithms to predict heart disease using patient medical data. This study attempts to compare the effectiveness of the Decision Tree and Random Forest algorithms in classifying heart disease using the Heart Disease dataset. The research steps included data collection, initial data cleaning and organization, data exploration (EDA), data division into training and testing sets, model training, and performance assessment using a Confusion Matrix and accuracy calculation. Based on the evaluation, the Decision Tree algorithm achieved an accuracy rate of 93.44% on the training data and 87.34% on the testing data. The Confusion Matrix analysis for this model recorded 123 True Negative cases, 146 True Positive cases, 27 False Positive cases, and 12 False Negative cases. Meanwhile, the Random Forest algorithm performed superior with a training accuracy of 99.02% and a testing accuracy of 97.73%. The confusion matrix for Random Forest recorded 147 true negatives, 154 true positives, 3 false positives, and 4 false negatives. These findings indicate that Random Forest



offers better accuracy and reduces prediction errors compared to Decision Tree. This indicates that Random Forest is more reliable in identifying data patterns related to heart disease and is better at generalizing its results. Thus, the Random Forest algorithm is recommended as a more effective approach for heart disease classification due to its ability to provide more accurate and stable predictions.

Keywords: Machine Learning, Decision Tree, Random Forest, Heart Disease, Classification.

1. PENDAHULUAN

Penyakit jantung tetap menjadi salah satu isu kesehatan global yang paling berbahaya di abad ke-21. Berdasarkan informasi terkini dari Global Burden of Disease dan Organisasi Kesehatan Dunia (WHO), angka penderita penyakit jantung koroner serta gagal jantung semakin meningkat di negara-negara berkembang (Nafisah et al., 2024). Data dari Riset Kesehatan Dasar (Riskesdas) menunjukkan bahwa di Indonesia, tingginya kasus hipertensi, diabetes, dan gaya hidup tidak aktif di perkotaan menyebabkan penyakit jantung menjadi penyebab kematian terbanyak setelah stroke. Tingginya jumlah kematian sering kali disebabkan oleh keterlambatan dalam deteksi dini; banyak pasien cenderung mengabaikan atau salah memahami gejala awal (Wahidin et al., 2025). Transformasi digital dalam sistem kesehatan melalui Rekam Medis Elektronik (EHR) telah menciptakan volume data medis yang sangat besar dalam beberapa tahun terakhir. Data tersebut, jika tidak diolah dengan benar, sering kali hanya menjadi kumpulan arsip. Penambangan data dan pembelajaran mesin muncul sebagai solusi untuk menarik informasi dari catatan medis pasien yang lalu (Pertiwi & Supryatno, 2023). Dengan memanfaatkan parameter klinis seperti usia, jenis kelamin, kadar kolesterol, tekanan darah, dan hasil elektrokardiogram, dokter dapat melakukan diagnosis yang lebih cepat, akurat, dan berbasis bukti (Ali & Idarus, 2024).

Seiring dengan perkembangan teknologi informasi, pemanfaatan machine learning dalam bidang kesehatan mengalami pertumbuhan yang signifikan. Machine learning mampu membantu sistem untuk memperoleh wawasan dari data sebelumnya serta mengenali pola-pola rumit, sehingga dapat digunakan untuk memprediksi kemungkinan munculnya penyakit, termasuk penyakit jantung. Dengan memanfaatkan data klinis seperti usia, tekanan darah, kadar kolesterol, dan riwayat kesehatan pasien, algoritma machine learning dapat memberikan prediksi yang akurat dan mendukung pengambilan keputusan berbasis informasi (Hussein et al., 2026).

Berbagai penelitian terbaru menunjukkan bahwa penerapan pembelajaran mesin dalam pengklasifikasian penyakit jantung menunjukkan hasil yang menjanjikan. Metode ini tidak hanya meningkatkan keakuratan diagnosis, tetapi juga berfungsi untuk mengidentifikasi faktor risiko utama yang berkontribusi pada penyakit jantung. Selain itu, model pembelajaran mesin mampu menangani data dalam jumlah besar dengan banyak variabel yang kompleks, sehingga lebih efisien dibandingkan metode konvensional yang memerlukan analisis manual (Alzboon & Al-batah, 2026).

Dalam kategori klasifikasi, dua metode yang paling lazim digunakan adalah Decision Tree dan Random Forest. Decision Tree merupakan algoritma yang sederhana dan mudah dipahami karena membangun struktur pohon keputusan yang jelas menggambarkan kaidah klasifikasi. Salah satu keunggulan utama algoritma ini adalah kemudahan dalam penafsirannya, sehingga sangat cocok untuk diterapkan di sektor kesehatan yang memerlukan kejelasan dalam proses pengambilan keputusan. Akan tetapi, Decision Tree juga memiliki kelemahan, yaitu rentan terhadap overfitting, terutama ketika data pelatihan memiliki kompleksitas tinggi atau banyak variabel (Rian Oktafiani, Arief Hermawan, 2026). Sebagai alternatif dari Decision Tree, Random



Forest mengadopsi prinsip pembelajaran ensemble, yang melibatkan gabungan beberapa pohon keputusan untuk menghasilkan prediksi yang lebih stabil dan akurat. Dengan menggunakan metode bootstrap aggregating (bagging), Random Forest dapat mengurangi variasi model dan meningkatkan kemampuan generalisasi. Hal ini menjadikan Random Forest lebih tahan terhadap overfitting dibandingkan dengan Decision Tree, serta lebih efektif dalam mengolah data yang tidak seimbang dan kompleks (Sudipta Priyadarshinee, 2022). Penelitian terbaru menunjukkan bahwa Random Forest seringkali memberikan hasil yang lebih baik dibandingkan dengan algoritma tunggal lainnya ketika mengklasifikasikan penyakit jantung. Misalnya, penelitian perbandingan menunjukkan bahwa Random Forest dapat mencapai akurasi yang tinggi, bahkan lebih dari 90% dalam beberapa kondisi, serta menunjukkan performa yang stabil dalam berbagai variasi data (Asgarabad, 2026). Meskipun demikian, Decision Tree tetap penting karena mudah dipahami, yang sangat berguna dalam sistem dukungan keputusan di dunia medis. Selain itu, kinerja kedua algoritma ini sangat dipengaruhi oleh berbagai aspek, termasuk kualitas data, teknik pemrosesan awal, pemilihan fitur, dan pengaturan hyperparameter. Faktor seperti kedalaman pohon maksimum, jumlah pohon dalam Random Forest, serta cara validasi model memiliki pengaruh besar terhadap hasil klasifikasi. Kesalahan dalam pengaturan parameter dapat menurunkan akurasi dan berisiko menghasilkan keputusan yang salah dalam konteks kesehatan (Rian Oktafiani, Arief Hermawan, 2026). Dalam penelitian lain juga dijelaskan bahwa penggunaan metode tambahan seperti pemilihan fitur, penyeimbangan dataset (seperti SMOTE), dan optimasi hyperparameter dapat secara signifikan meningkatkan kinerja model. Ini menunjukkan bahwa keberhasilan model machine learning tidak hanya bergantung pada algoritma yang digunakan, tetapi juga pada metode pengolahan data yang tepat (Sudipta Priyadarshinee, 2022).

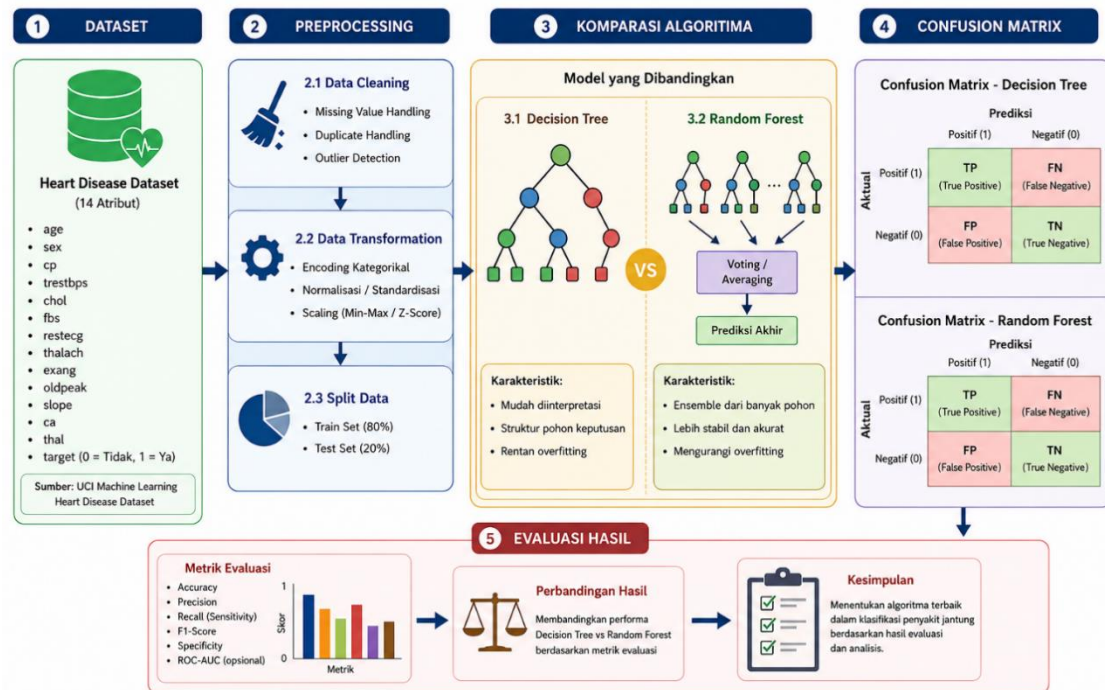
Berdasarkan berbagai penelitian tersebut, dapat disimpulkan bahwa baik Decision Tree maupun Random Forest masing-masing memiliki kelebihan dan kekurangan. Oleh karena itu, perlu dilakukan analisis perbandingan yang mendalam untuk menilai seberapa efektif kedua algoritma ini dalam mengklasifikasikan penyakit jantung. Penelitian ini diharapkan dapat memberikan kontribusi dalam menemukan model terbaik yang tidak hanya memiliki tingkat akurasi tinggi, tetapi juga efisien dan mudah dipahami dalam konteks medis. Dengan kata lain, penelitian ini bertujuan untuk menganalisis kinerja algoritma Decision Tree dan Random Forest dalam klasifikasi penyakit jantung, sehingga dapat diperoleh model yang paling optimal dan berfungsi sebagai landasan untuk pengembangan sistem dukungan keputusan dalam sektor kesehatan.

2. METODE PENELITIAN

Penelitian menggunakan metode kuantitatif untuk melakukan klasifikasi kelas target tertentu pada penyakit jantung. Tahapan penelitian ini adalah untuk melakukan klasifikasi algoritma machine learning pada penyakit jantung berdasarkan data dan atribut yang terdapat pada dataset *heart disease* dalam menentukan apakah pasien tersebut memiliki penyakit jantung dengan nilai luaran "1" atau tidak memiliki penyakit jantung dengan nilai "0". Pada penelitian ini menerapkan kerangka kerja pada proses KDD (*Knowledge Discovery in Databases*) yang merupakan proses sistematis untuk menemukan pengetahuan atau pola baru yang berguna dari dataset yang besar. KDD tidak hanya sekadar data mining, tetapi mencakup seluruh tahapan mulai dari pemahaman masalah hingga interpretasi hasil. Adapun tahapan KDD yang akan diterapkan pada penelitian ini melakukan proses, *Data Selection, Data Preprocessing, Data Transformation, Klasifikasi dan Evaluation*. Tahapan penelitian dengan kerangka kerja KDD dapat ditunjukkan pada Gambar 1.



TAHAPAN PENELITIAN



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Dataset

Penelitian yang dilakukan menggunakan dataset penyakit jantung yang bersumber dari repository UCI dengan 1025 data serta memiliki 14 variabel. Berikut contoh dari dataset penyakit jantung pada Tabel 1.

Tabel 1. Contoh Dataset Penyakit Jantung

age	sex	cp	trestbps	chol	fbs	restecg	thalach	exang	oldpeak	slope	ca	thal	target
52	1	0	125	212	0	1	168	0	1	2	2	3	0
53	1	0	140	203	1	0	155	1	3.1	0	0	3	0
70	1	0	145	174	0	1	125	1	2.6	0	0	3	0
61	1	0	148	203	0	1	161	0	0	2	1	3	0
62	0	0	138	294	1	1	106	0	1.9	1	3	2	0
58	0	0	100	248	0	0	122	0	1	1	0	2	1
58	1	0	114	318	0	2	140	0	4.4	0	3	1	0
55	1	0	160	289	0	0	145	1	0.8	1	1	3	0
46	1	0	120	249	0	0	144	0	0.8	2	0	3	0
54	1	0	122	286	0	0	116	1	3.2	1	2	2	0

Tabel 2. Variabel Dataset *Heart Disease*

Atribut	Deskripsi
age	Menunjukkan usia pasien dalam satuan tahun.
sex	Menunjukan jenis kelamin dengan nilai 1 = Laki-laki, 0 = Perempuan
Cp	merupakan tipe nyeri dada dengan nilai 0 = typical angina (nyeri khas jantung), 1 = atypical angina, 2 = non-anginal pain, 3 = asymptomatic (tanpa gejala)
trestbps	Tekanan darah saat kondisi istirahat (mmHg).



chol	Kadar kolesterol dalam darah (mg/dl).
fbs	Gula darah tinggi bisa menjadi indikasi diabetes, yang berkaitan dengan penyakit jantung dengan nilai 1 = > 120 mg/dl dan 0 = ≤ 120 mg/dl
restecg	Digunakan untuk mendeteksi gangguan listrik pada jantung, dengan nilai 0 = normal, 1 = kelainan gelombang ST-T dan 2 = kemungkinan hipertrofi ventrikel kiri
thalach	Detak jantung maksimum yang dicapai saat latihan.
exang	Menunjukkan apakah pasien mengalami nyeri dada saat aktivitas fisik dengan nilai 1 = ya dan 0 = tidak
oldpeak	Digunakan untuk mendeteksi iskemia (kurangnya aliran darah ke jantung).
slope	Kemiringan segmen ST saat puncak Latihan dengan nilai 0 = upsloping, 1 = flat dan 2 = downsloping
ca	Jumlah pembuluh darah utama (0–3) yang terlihat melalui fluoroskopi.
thal	Digunakan untuk melihat gangguan aliran darah jantung dengan nilai 1 = normal, 2 = fixed defect dan 3 = reversible defect
target	variabel target yang akan diprediksi oleh model machine learning dengan nilai 1 = memiliki penyakit jantung dan 0 = tidak memiliki penyakit jantung

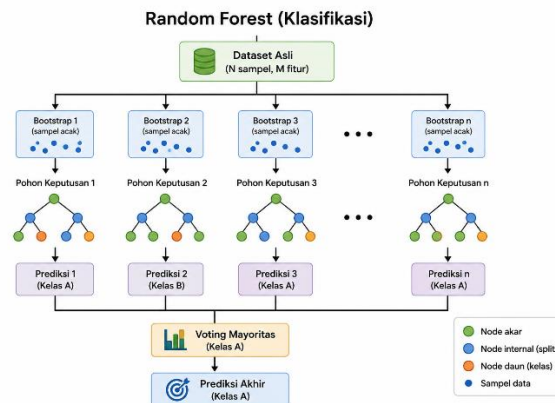
2.2 Pre Processing

Data preprocessing merupakan tahap yang sangat penting dalam machine learning karena bertujuan untuk mengolah data mentah menjadi data berkualitas yang siap digunakan untuk pemodelan. Kualitas data yang baik berpengaruh besar terhadap kinerja model yang dihasilkan. Oleh karena itu, langkah preprocessing dilakukan untuk mengatasi berbagai masalah dalam data, seperti nilai yang hilang, data yang sama, serta adanya noise atau outlier yang bisa mengganggu proses belajar model. Preprocessing menjadi salah satu komponen utama yang menentukan keberhasilan model karena dapat memperbaiki kualitas data dan meningkatkan akurasi prediksi (Mu et al., 2026). Dalam studi ini, proses preprocessing dimulai dengan pembersihan data, yang melibatkan identifikasi dan penanganan nilai hilang, penghapusan data yang duplikat, serta deteksi dan penanganan outlier. Penanganan nilai yang hilang dapat dilakukan dengan metode imputasi, seperti menggunakan rata-rata, median, atau modus, tergantung pada sifat data tersebut. Selain itu, deteksi outlier sangat penting untuk memastikan bahwa nilai ekstrim yang tidak normal tidak mempengaruhi hasil analisis. Hal ini sejalan dengan penelitian yang menunjukkan bahwa pembersihan data memiliki peranan penting dalam meningkatkan keakuratan model prediksi. Tahap berikutnya adalah transformasi data, yang bertujuan untuk mengubah data ke dalam format yang sesuai agar dapat diproses oleh algoritma machine learning. Pada tahap ini, dilakukan encoding terhadap variabel kualitatif, seperti label encoding atau one-hot encoding (Charaf et al., 2023). Menurut Springer (2025), transformasi data sangat penting untuk meningkatkan performa model dan mencegah dominasi dari fitur tertentu dalam proses pembelajaran. Setelah itu, data dibagi menjadi data latih dan data uji. Secara umum, pembagian ini memiliki proporsi 80% untuk data latih dan 20% untuk data uji. Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk mengevaluasi kinerja model dalam memprediksi data yang sebelumnya tidak diketahui. Hal ini didukung oleh penelitian dari (Dagal & Idriss, 2025) yang menegaskan ini sangat penting untuk memastikan bahwa model memiliki kemampuan generalisasi yang baik. Penelitian dari akademisi lainnya juga menegaskan bahwa pembagian data yang baik dapat mengurangi risiko overfitting. Dengan melakukan preprocessing yang tepat, diharapkan data yang digunakan dalam penelitian ini menjadi lebih bersih, terstruktur, dan representatif. Hal ini tentu akan berpengaruh pada peningkatan akurasi serta stabilitas dari model klasifikasi yang dibangun, terutama dalam membandingkan kinerja algoritma Random Forest dan Decision Tree dalam



klasifikasi penyakit jantung. Selain itu, optimasi pada preprocessing juga dapat meningkatkan efisiensi dan efektivitas dari keseluruhan proses machine learning.

2.3 Algoritma Random Forest



Gambar 2. Algoritma Random Forest

Random Forest adalah sebuah metode pembelajaran berbasis kelompok yang digunakan untuk tugas regresi, klasifikasi, dan lain-lain. Teknik ini terbentuk dari sejumlah pohon keputusan. Random Forest mengkombinasikan hasil dari semua pohon keputusan selama proses pelatihan untuk menentukan kelas dalam masalah klasifikasi dan menghitung rata-rata prediksi dalam model regresi. Algoritma ini mengatasi masalah overfitting pada data pelatihan, yang menjadi tantangan utama dalam algoritma pohon keputusan. Random Forest (RF) adalah kumpulan pengklasifikasi dasar yang dibangun secara bertingkat dalam bentuk pohon. Data biasanya memiliki banyak dimensi. Dataset sering kali mengandung banyak atribut yang tidak berguna. Hanya sedikit atribut yang menyimpan informasi krusial untuk model klasifikasi. Algoritma RF memanfaatkan probabilitas sederhana yang sudah ditentukan untuk memilih atribut penting yang sesuai. Breiman mengembangkan algoritma RF menggunakan subset dari data sampel dan membuat beberapa pohon keputusan dengan mengambil sampel acak dari subruang fitur (Hutagalung et al., 2026). Langkah-langkah dalam algoritma Random Forest adalah sebagai berikut:

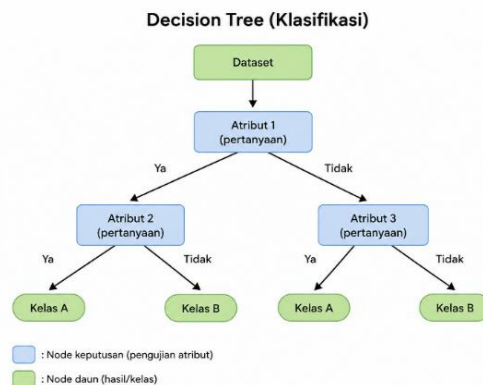
- 1) Tentukan jumlah tree (k) yang akan dibentuk, jumlah k dipilih dari total fitur m , di mana k kurang dari m .
- 2) Sampel acak diambil sebanyak N observasi (with replacement) pada dataset untuk setiap tree
- 3) Pada setiap tree, dilakukan juga pengambilan subset prediktor sebanyak secara acak. Dimana m proses kedua dan ketiga diulangi sampai sebanyak k tree.
- 4) Pada kasus klasifikasi, hasil prediksi Random Forest diperoleh dari vote terbanyak (majority vote) dari hasil klasifikasi sebanyak tree.

2.4 Algoritma Decision Tree

Decision Tree adalah salah satu algoritma dalam pembelajaran mesin yang termasuk dalam kategori pembelajaran terawasi dan cocok untuk tugas klasifikasi maupun regresi. Algoritma ini berfungsi dengan menciptakan model dalam bentuk pohon, yang terdiri dari node akar, node internal untuk menguji atribut, serta node daun yang menunjukkan hasil prediksi. Decision Tree terkenal karena mudah dipahami, karena menghasilkan aturan keputusan yang serupa dengan cara manusia berpikir saat membuat pilihan. Proses pembentukan Decision Tree dimulai dengan menempatkan seluruh data di node akar, lalu memilih atribut terbaik untuk



pemisahan. Pemilihan atribut ini dilakukan berdasarkan kriteria tertentu seperti Information Gain, Gain Ratio, atau Gini Index, dengan tujuan agar pembagian data yang dihasilkan optimal dan seragam. Proses ini berlangsung secara berulang hingga mencapai kondisi tertentu, seperti ketika data dalam satu node sudah seragam atau tidak ada atribut lain yang dapat digunakan lagi.



Gambar 3. Algoritma Decision Tree

Decision Tree efektif untuk mengidentifikasi pola dalam data yang kompleks dan berdimensi tinggi karena kemampuannya dalam membagi data secara terstruktur. Dalam praktiknya, Decision Tree telah banyak diterapkan dalam berbagai penelitian, salah satunya dalam klasifikasi penyakit jantung. Decision Tree dapat diaplikasikan untuk menganalisis data medis dan menghasilkan model prediksi yang cukup memuaskan melalui langkah-langkah pengolahan awal, pelatihan, dan evaluasi model. Berikut tahapan dari algoritma Decision Tree:

- 1) Menentukan *Root Node* untuk Memilih atribut terbaik sebagai pemisah awal menggunakan kriteria seperti *Gini Index* atau *Information Gain*.
- 2) Splitting Data atau membagi data menjadi beberapa subset berdasarkan atribut terpilih.
- 3) Pembentukan Cabang, dimana mengulangi proses pemilihan atribut dan pembagian data secara rekursif pada setiap cabang
- 4) Stopping Criteria, saat proses berhenti jika data sudah homogen, tidak ada atribut tersisa, atau mencapai batas tertentu (misalnya *max depth*).
- 5) Leaf Node (Hasil Akhir) di setiap daun berisi keputusan atau label kelas.

2.5 Confusion Matrix

		Prediksi	
		Positif (1)	Negatif (0)
Aktual	Positif (1) (Actual Positive)	True Positive (TP) Jumlah data positif yang diprediksi benar (positif)	False Negative (FN) Jumlah data positif yang diprediksi salah (negatif)
	Negatif (0) (Actual Negative)	False Positive (FP) Jumlah data negatif yang diprediksi salah (positif)	True Negative (TN) Jumlah data negatif yang diprediksi benar (negatif)

Gambar 4. Confusion Matrix

Confusion Matrix adalah metode evaluasi yang digunakan untuk menilai kinerja model klasifikasi dalam pembelajaran mesin. Metode ini menyajikan hasil prediksi model dalam format tabel yang membandingkan nilai sebenarnya dengan nilai yang diprediksi, sehingga memberikan penjelasan yang lebih mendalam mengenai kinerja model. Selain mengukur tingkat akurasi, Confusion Matrix juga dapat mengenali jenis kesalahan yang dibuat oleh model, sehingga sangat krusial dalam analisis kinerja klasifikasi. Sokolova dan Lapalme menyatakan bahwa evaluasi yang



didasarkan pada Confusion Matrix menyediakan informasi yang lebih lengkap dibandingkan dengan metrik tunggal karena mencakup semua kemungkinan hasil prediksi. Confusion Matrix terdiri dari empat elemen utama, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). True Positive menunjukkan jumlah data yang dengan tepat dikategorikan sebagai kelas positif, sementara True Negative menunjukkan jumlah data yang benar diklasifikasikan sebagai kelas negatif. Di sisi lain, False Positive terjadi ketika model keliru mengidentifikasi data negatif sebagai positif, dan False Negative terjadi saat data positif dikategorikan sebagai negatif. Keempat elemen ini digunakan untuk menghitung berbagai metrik evaluasi seperti akurasi, presisi, recall, dan F1-score, yang masing-masing memberikan sudut pandang yang berbeda terhadap kinerja model.

Terdapat penelitian sebelumnya yang relevan dengan penelitian yang akan di lakukan dengan topik komparasi algoritma Random Forest dan Decision Tree dalam klasifikasi penyakit jantung. Berikut penelitian yang relevan di muat pada Tabel 3.

Tabel 3. Penelitian Terkait

No	Nama Peneliti dan Tahun	Masalah Penelitian	Metode	Hasil
1	(Kohsasih et al., 2026)	Rendahnya akurasi deteksi dini penyakit jantung menggunakan metode konvensional	Random Forest, Logistic Regression	Random Forest menunjukkan akurasi tertinggi 89% dibanding metode Logistic Regression
2	(Rian Oktafiani, Arief Hermawan, 2026)	Pengaruh parameter max depth terhadap performa klasifikasi penyakit jantung	Decision Tree, Random Forest	Random Forest lebih stabil, Decision Tree rentan overfitting jika depth terlalu tinggi
3	(Pratama et al., 2026)	Perbandingan performa beberapa algoritma dalam klasifikasi penyakit jantung	Random Forest, XGBoost, C4.5	Random Forest memiliki performa tinggi dan konsisten 91%
4	(Hutagalung et al., 2026)	Kurangnya interpretabilitas model dalam prediksi penyakit jantung	Random Forest + SHAP (Explainable AI)	Model Random Forest akurat dan dapat dijelaskan dengan SHAP
5	(Fitri et al., 2024)	Kebutuhan model prediksi penyakit jantung yang akurat pada dataset kompleks	Decision Tree, Random Forest, SVM	Random Forest unggul dalam akurasi dan generalisasi dibanding Decision Tree
6	(Effendy et al., 2024)	Ketidakseimbangan dataset (imbalanced data) dalam klasifikasi penyakit jantung	SMOTE + Random Forest, Decision Tree	Random Forest dengan SMOTE meningkatkan akurasi signifikan 90%

Berdasarkan riset-riset sebelumnya mengenai diagnosis penyakit jantung, diketahui bahwa penggunaan teknik machine learning dapat secara substansial menaikkan ketepatan perkiraan dibandingkan metode tradisional. Sejumlah penelitian telah berusaha meningkatkan kinerja model dengan berbagai algoritma, meliputi Random Forest, Decision Tree, Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan Logistic Regression. Hasil dari berbagai investigasi ini mengungkapkan bahwa Random Forest cenderung menunjukkan tingkat akurasi dan konsistensi yang lebih baik daripada algoritma lain, berkat kemampuannya menekan potensi overfitting melalui pendekatan ensemble learning. Di sisi lain, Decision Tree masih sering digunakan karena keunggulannya dalam hal kemudahan interpretasi dan pemahaman alur pengambilan keputusan, walaupun memiliki kelemahan terkait overfitting apabila

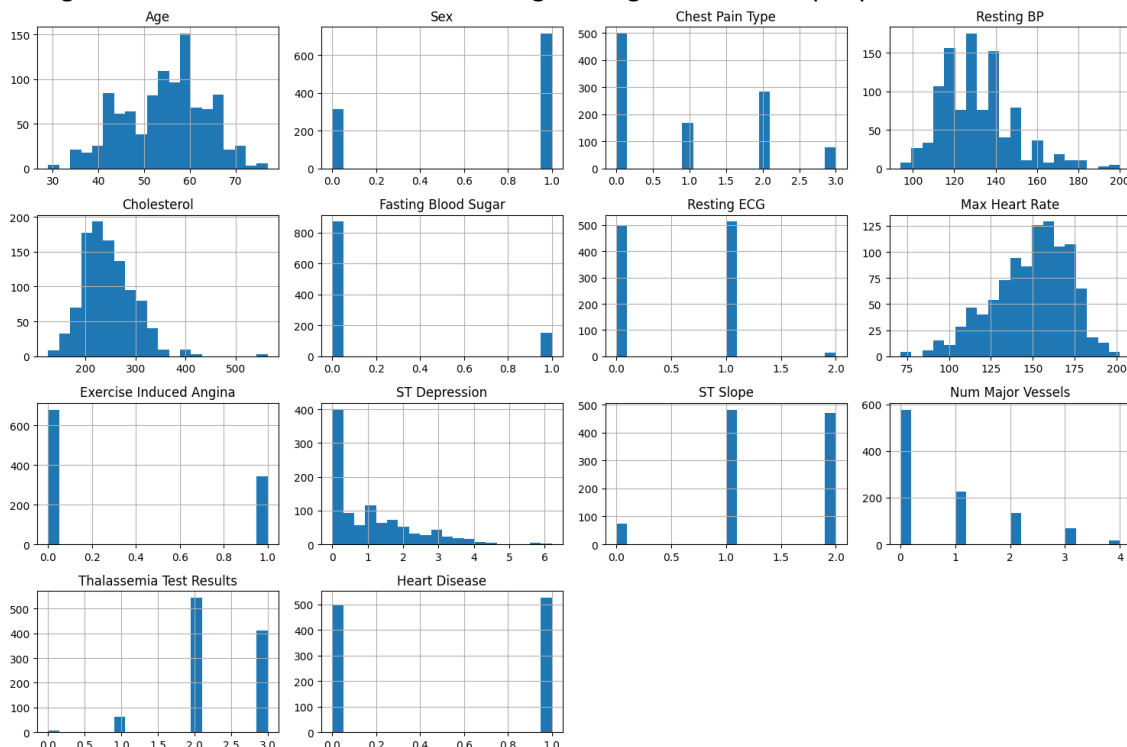


parameternya tidak diatur dengan cermat. Lebih lanjut, banyak studi juga menggabungkan teknik tambahan seperti pemilihan fitur, tuning hyperparameter, dan penanganan ketidakseimbangan data melalui metode seperti SMOTE untuk menyempurnakan kinerja model. Ternyata, metode-metode tersebut terbukti mampu meningkatkan akurasi dan performa klasifikasi secara signifikan. Akan tetapi, mayoritas penelitian terdahulu cenderung membandingkan berbagai algoritma secara bersamaan, sehingga tidak menyajikan analisis mendalam terkait perbandingan antara dua algoritma spesifik, terutama antara Random Forest dan Decision Tree. Hal ini menyebabkan kurangnya analisis terperinci mengenai kelebihan dan kekurangan masing-masing algoritma dalam konteks yang lebih spesifik. Dengan mempertimbangkan situasi tersebut, penelitian ini hadir dengan fokus yang lebih jelas, yaitu mengulas perbandingan kinerja antara algoritma Random Forest dan Decision Tree dalam pengklasifikasian penyakit jantung.

3. HASIL DAN PEMBAHASAN

3.1 Explorasi Data

Tahap Exploratory Data Analysis (EDA) dilakukan untuk memahami karakteristik dataset penyakit jantung sebelum proses pemodelan dilakukan. Dataset yang digunakan terdiri dari beberapa variabel medis yang berkaitan dengan kondisi pasien, seperti usia (age), jenis kelamin (sex), tipe nyeri dada (cp), tekanan darah istirahat (trestbps), kadar kolesterol (chol), gula darah puasa (fbs), hasil elektrokardiogram (restecg), detak jantung maksimum (thalach), nyeri dada akibat olahraga (exang), nilai oldpeak, kemiringan segmen ST (slope), jumlah pembuluh darah utama (ca), hasil tes thalassemia (thal), serta variabel target (target) yang menunjukkan keberadaan penyakit jantung. Berikut eksplorasi data yang dilakukan dengan menggunakan histogram untuk melihat distribusi dari masing-masing variabel terdapat pada Gambar 5.



Gambar 5. Histogram dataset *heart disease*

Hasil histogram dari dataset mengenai penyakit jantung memberikan gambaran mengenai sebaran masing-masing variabel dalam studi ini. Tujuan dari visualisasi ini adalah



untuk meneliti pola data, distribusi nilai, dan karakteristik tiap fitur sebelum proses pemodelan dimulai menggunakan algoritma pembelajaran mesin. Mengenai variabel Usia, mayoritas pasien dapat ditemukan dalam kisaran 40 hingga 65 tahun. Hal ini menunjukkan bahwa risiko mengalami penyakit jantung lebih umum terjadi pada orang dewasa sampai lanjut usia. Penyebaran usia menunjukkan pola yang mendekati distribusi normal, dengan konsentrasi tertinggi pada usia sekitar 55 tahun. Untuk variabel Jenis Kelamin, terlihat bahwa jumlah pasien laki-laki lebih banyak dibandingkan dengan perempuan. Ini menandakan bahwa dalam dataset ini, proporsi pasien laki-laki lebih dominan, yang sejalan dengan fakta bahwa penyakit jantung lebih sering ditemui pada pria dibandingkan wanita pada usia tertentu. Dalam fitur Jenis Nyeri Dada, terlihat bahwa kategori 0 dan 2 memiliki jumlah individu yang lebih tinggi dibandingkan kategori lainnya. Variabel ini memiliki peranan penting karena nyeri dada merupakan salah satu gejala utama dalam mendiagnosis penyakit jantung. Distribusi Tekanan Darah Istirahat menunjukkan bahwa sebagian besar pasien memiliki tekanan darah istirahat dalam kisaran 110 sampai 140 mmHg. Namun, terdapat beberapa nilai ekstrem yang melebihi 180 mmHg, yang mengindikasikan kemungkinan adanya outlier atau pasien dengan hipertensi berat. Pada fitur Kadar Kolesterol, mayoritas pasien memiliki kadar kolesterol antara 200 hingga 300 mg/dl. Selain itu, terdapat juga sejumlah nilai yang sangat tinggi, sehingga menunjukkan distribusi yang tidak simetris. Kondisi ini menunjukkan adanya pasien yang memiliki kadar kolesterol tinggi, yang dapat meningkatkan risiko penyakit jantung. Selanjutnya, Kadar Gula Puasa menunjukkan bahwa sebagian besar pasien memiliki kadar gula puasa yang normal (nilai 0), sedangkan hanya sedikit pasien yang memiliki kadar gula di atas 120 mg/dl (nilai 1). Ini menunjukkan bahwa distribusi data pada fitur ini tidak seimbang.

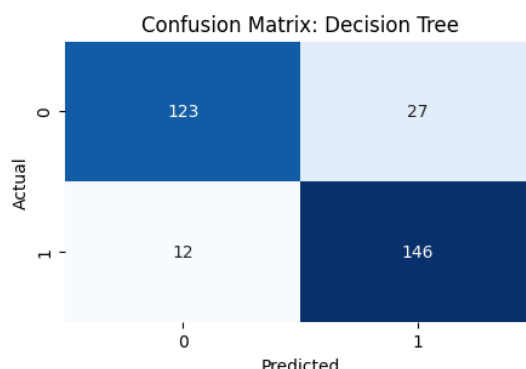
Mengenai fitur Elektrokardiogram Istirahat, sebagian besar data termasuk dalam kategori 0 dan 1, sementara kategori 2 memiliki jumlah yang jauh lebih sedikit. Hal ini menunjukkan bahwa mayoritas pasien memiliki hasil elektrokardiogram yang normal atau hanya mengalami gangguan ringan. Di sisi lain, distribusi Detak Jantung Maksimum menunjukkan pola yang mendekati distribusi normal dengan puncak antara 140 hingga 170 denyut per menit. Variabel ini mencerminkan kemampuan jantung pasien saat beraktivitas fisik. Variabel Angina yang dipicu oleh aktivitas fisik menunjukkan bahwa sebagian besar pasien tidak mengalami nyeri dada saat berolahraga (nilai 0). Di sisi lain, nilai 1 menunjukkan adanya pasien yang merasakan gejala angina akibat olahraga atau aktivitas intensif. Pada fitur ST Depression, distribusi data cenderung mengarah ke kanan, dengan sebagian besar nilai berada di bawah angka 2. Nilai oldpeak yang lebih tinggi bisa menunjukkan adanya masalah pada aliran darah menuju jantung. Distribusi ST Slope menunjukkan bahwa jumlah data pada kategori 1 dan 2 lebih banyak dibandingkan dengan kategori 0. Variabel ini berfungsi untuk menilai hasil elektrokardiogram saat melakukan aktivitas fisik. Terkait fitur Jumlah Pembuluh Utama, sebagian besar pasien memiliki nilai 0, yang menunjukkan tidak adanya penyempitan di pembuluh darah besar. Namun, terdapat beberapa pasien yang memiliki nilai sampai 4, yang menunjukkan kemungkinan adanya masalah jantung yang lebih serius. Hasil Uji Variabel Hasil Tes Thalassemia memperlihatkan prevalensi yang tinggi pada kategori 2 dan 3. Ini mengindikasikan bahwa mayoritas pasien menunjukkan hasil yang berkaitan dengan masalah sirkulasi darah di jantung. Terakhir, pada variabel Penyakit Jantung, terlihat bahwa distribusi antara pasien yang menderita penyakit jantung dan yang tidak cukup seimbang. Kondisi ini sangat menguntungkan untuk proses klasifikasi, karena dapat membantu model machine learning untuk beradaptasi dengan lebih efektif tanpa ada bias pada salah satu kelompok.

3.2 Evaluasi Model dengan Confusion Matrix

Pengujian yang dilakukan pada dataset heart disease menggunakan pembagian data sebesar 70% untuk data training sedangkan untuk data testing sebesar 30%. Hasil dari pengujian menggunakan algoritma Decision Tree sebesar 87.34% dan algoritma Random Forest sebesar




97.73%, dari hasil pengujian tersebut akurasi tertinggi yang didapatkan oleh algoritma Random Forest, sedangkan hasil dari confusion matrix dihasilkan dalam bentuk gambar sebagai berikut.



Gambar 6. Confusion Matrix Decision Tree

Berdasarkan hasil Confusion Matrix, model Decision Tree menghasilkan 123 data *True Negative (TN)*, yaitu pasien yang tidak memiliki penyakit jantung dan berhasil diprediksi dengan benar sebagai negatif. Selain itu, model juga menghasilkan 146 data *True Positive (TP)*, yaitu pasien yang memiliki penyakit jantung dan berhasil diprediksi dengan benar sebagai positif. Jumlah prediksi benar yang cukup tinggi ini menunjukkan bahwa Decision Tree mampu mengenali pola utama pada dataset penyakit jantung. Namun, masih terdapat 27 data *False Positive (FP)*, yaitu pasien yang sebenarnya tidak memiliki penyakit jantung tetapi diprediksi sebagai positif oleh model. Nilai FP yang cukup besar menunjukkan bahwa model cenderung memberikan prediksi positif secara berlebihan pada beberapa kasus. Dalam konteks medis, kesalahan ini dapat menyebabkan pasien sehat menjalani pemeriksaan tambahan yang sebenarnya tidak diperlukan. Walaupun dampaknya tidak seberbahaya *False Negative*, jumlah FP yang tinggi dapat meningkatkan biaya pemeriksaan dan mengurangi efisiensi sistem diagnosis. Selain itu, model menghasilkan 12 data *False Negative (FN)*, yaitu pasien yang sebenarnya memiliki penyakit jantung tetapi diprediksi sebagai sehat. Pada bidang kesehatan, kesalahan FN merupakan jenis kesalahan yang paling kritis karena pasien yang seharusnya mendapatkan penanganan medis justru tidak terdeteksi oleh sistem. Walaupun jumlah FN pada model ini lebih kecil dibanding FP, keberadaan kesalahan ini tetap menjadi perhatian penting karena dapat berdampak pada keterlambatan diagnosis dan penanganan pasien. Jika dianalisis lebih lanjut, model Decision Tree memiliki kemampuan klasifikasi yang cukup baik dalam membedakan kelas positif dan negatif, namun masih terdapat keterbatasan dalam menangani kompleksitas pola data. Hal ini disebabkan karena Decision Tree hanya menggunakan satu struktur pohon keputusan dalam proses klasifikasi. Ketika data memiliki banyak variasi atau pola non-linear yang kompleks, satu pohon keputusan cenderung kurang stabil dan lebih sensitif terhadap perubahan data. Dari sisi performa model, nilai akurasi pengujian sebesar 87,34% sebenarnya sudah termasuk kategori baik untuk klasifikasi medis. Akan tetapi, selisih antara akurasi pelatihan dan pengujian menunjukkan bahwa model belum memiliki kemampuan generalisasi yang optimal. Hal ini menandakan bahwa model cukup baik dalam mengenali data yang pernah dipelajari, tetapi masih mengalami kesulitan ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya.



Gambar 7. Confusion Matrix Random Forest

Berdasarkan hasil pengujian menggunakan algoritma Random Forest, diperoleh performa model yang sangat baik dalam melakukan klasifikasi data. Hal ini terlihat dari nilai *train accuracy* sebesar 0,9902 atau 99,02%, yang menunjukkan bahwa model mampu mempelajari pola pada data pelatihan dengan sangat baik. Selain itu, nilai *test accuracy* sebesar 0,9773 atau 97,73% menunjukkan bahwa model juga mampu melakukan prediksi secara akurat pada data pengujian. Selisih antara akurasi pelatihan dan pengujian yang relatif kecil mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan dan memiliki kemampuan generalisasi yang baik terhadap data baru. Berdasarkan confusion matrix, model berhasil memprediksi sebanyak 147 data kelas 0 dengan benar (*true negative*) dan 154 data kelas 1 dengan benar (*true positive*). Sementara itu, terdapat 3 data dari kelas 0 yang salah diprediksi sebagai kelas 1 (*false positive*) dan 4 data dari kelas 1 yang salah diprediksi sebagai kelas 0 (*false negative*). Jumlah kesalahan prediksi yang sangat sedikit dibandingkan jumlah prediksi yang benar menunjukkan bahwa model Random Forest mampu membedakan kedua kelas dengan tingkat ketepatan yang tinggi. Secara keseluruhan, hasil ini menunjukkan bahwa algoritma Random Forest memiliki performa yang sangat optimal dan layak digunakan sebagai model klasifikasi pada dataset yang diteliti.

4. KESIMPULAN

Berdasarkan hasil pengujian dan evaluasi model, dapat disimpulkan bahwa algoritma Random Forest memiliki performa yang lebih baik dibandingkan algoritma Decision Tree dalam melakukan klasifikasi penyakit jantung. Hal ini terlihat dari nilai *test accuracy* Random Forest sebesar 97,73% dan *train accuracy* 98,90%, yang lebih tinggi dibandingkan Decision Tree menghasilkan *test accuracy* 87,34% dan *train accuracy* 84,63%. Selain itu, Random Forest juga menunjukkan kemampuan generalisasi yang lebih baik karena selisih antara *train accuracy* dan *test accuracy* relatif kecil, sehingga model tidak mengalami *overfitting* secara signifikan. Hasil evaluasi menggunakan Confusion Matrix juga menunjukkan bahwa Random Forest menghasilkan jumlah kesalahan prediksi yang lebih sedikit dibandingkan Decision Tree. Pada Random Forest, hanya terdapat 3 False Positive dan 4 False Negative, sedangkan Decision Tree menghasilkan 27 False Positive dan 12 False Negative. Dalam konteks klasifikasi penyakit jantung, nilai False Negative sangat penting untuk diperhatikan karena kesalahan ini menyebabkan pasien yang sebenarnya memiliki penyakit jantung diprediksi sebagai sehat. Oleh karena itu, jumlah False Negative yang lebih kecil pada Random Forest menunjukkan bahwa algoritma ini lebih efektif dalam mendeteksi pasien yang benar-benar memiliki penyakit jantung. Perbedaan performa tersebut disebabkan karena Random Forest menggunakan metode ensemble learning dengan membangun banyak pohon keputusan (decision tree) dan menggabungkan hasil prediksi melalui metode majority voting. Pendekatan ini membuat



Random Forest lebih stabil, lebih akurat, dan mampu mengurangi risiko overfitting dibandingkan Decision Tree yang hanya menggunakan satu pohon keputusan.

DAFTAR PUSTAKA

- Ali, H., & Idarus, A. (2024). Perlindungan Hukum Bagi Pasien Dokter Online Menurut Hukum Positif dan Maqashid Syariah. *Innovative: Journal Of Social Science Research*, 4(4), 3102–3119. <https://doi.org/https://doi.org/10.31004/innovative.v4i4.12293>
- Alzboon, M. S., & Al-batah, M. S. (2026). A clinically accessible heart disease prediction framework : multi-model evaluation with ensemble learning and low-code deployment. *Alzboon and Al-Batah Discover Applied Sciences*, 8(1), 1–12. <https://doi.org/https://doi.org/10.1007/s42452-026-08353-2>
- Asgarabad, M. E. (2026). A comprehensive comparative analysis of machine learning algorithms in heart disease prediction. *Discover Artificial Intelligence*, 6(1), 1–23. <https://doi.org/https://doi.org/10.1007/s44163-026-01048-y>
- Charaf, N., Haase, J., Kulisch, A., Von Elm, C., & Göhringer, D. (2023). RTASS: a RunTime Adaptable and Scalable System for Network-on-Chip-Based Architectures. *2023 26th Euromicro Conference on Digital System Design (DSD)*, 585–592. <https://doi.org/10.1109/DSD60849.2023.00086>
- Dagal, & Idriss. (2025). Comprehensive evaluation of data preprocessing and visualization techniques for enhanced classification and sampling. In *Cluster Computing* (Vol. 28, Issue 7). Springer US. <https://doi.org/10.1007/s10586-025-05512-9>
- Fitri, A., Masruriyah, N., Novita, H. Y., Sukmawati, C. E., & Ramadhan, A. R. (2024). Pengukuran Kinerja Model Klasifikasi dengan Data Oversampling pada Algoritma Supervised Learning untuk Penyakit Jantung. *Computer Science (CO-SCIENCE)*, 4(1), 62–70. <https://doi.org/https://doi.org/10.31294/coscience.v4i1.2389>
- Hussein, D. R., Alhumaima, A. S., Alkattan, H., & Abotaleb, M. (2026). Performance Evaluation of Logistic Regression , Random Forest , and SVM Models in Heart Disease Prediction. *Journal of Transactions in Systems Engineering*, 4(1), 522–537. <https://doi.org/https://doi.org/10.15157/JTSE.2026.4.1.522-537>
- Hutagalung, P. H., Informasi, S., & Nasional, U. (2026). Heart Disease Classification Using Optimised XGBoost and Random Forest with SHAP Explanations. *Sinkron : Jurnal Dan Penelitian Teknik Informatika*, 10(1), 330–342. <https://doi.org/https://doi.org/10.33395/sinkron.v10i1.15544>
- Kohsasih, K. L., Sunario, D. S., & Laurendio, F. (2026). Enhancing Early Heart Disease Detection Through Comparative Analysis of Random Forest , Decision Tree , and K-NN Models. *IT Journal Research and Development (ITJRD)*, 10(2), 66–77. <https://doi.org/https://doi.org/10.25299/itjrd.2025.24703>
- Mu, W., Cardelli, R., & Ferrari, S. (2026). Data Preprocessing Techniques for Machine Learning Towards Improving Building Energy Performance: A Systematic Review. In *Energies* (Vol. 19, Issue 6, p. 1561). <https://doi.org/10.3390/en19061561>
- Nafisah, S., Inayah, N. N., & Yusuf, B. (2024). Literatur Review : Penyebab dan Perkembangan Penyakit Jantung Koroner. *Jurnal Forum Kesehatan : Media Publikasi Kesehatan Ilmiah*, 14(1), 27–36. <https://doi.org/https://doi.org/10.52263/jfk.v14i1.254>
- Pertiwi, T. S., & Supryatno, A. (2023). Literatur Review : Dampak Implementasi Electronic Health Records (EHR) Di Pelayanan Kesehatan. *Journal of Baja Health Science (JOUBAHS)*, 03(1), 61–77. <https://doi.org/https://doi.org/10.47080/joubahs.v3i01.2454>
- Pratama, A., Assegaff, S., Jasmir, J., & Nurhadi, N. (2026). Optimizing Heart Disease Classification Using C4 . 5 , Random Forest , and XGBoost with ANOVA , Chi-Square , and AdaBoost. *Jurnal Teknik Informatika (JUTIF)*, 7(2), 1072–1090.



<https://doi.org/https://doi.org/10.52436/1.jutif.2026.7.2.5430>

- Rian Oktafiani, Arief Hermawan, D. A. (2026). Max Depth Impact on Heart Disease Classification: Decision Tree and Random Forest. (*Rekayasa Sistem Dan Teknologi Informasi*, 5(158), 160–168.
- Sudipta Priyadarshinee, M. P. (2022). CARDIAC DISEASE PREDICTION USING SMOTE AND MACHINE LEARNING CLASSIFIERS. *Journal of Pharmaceutical Negative Results*, 13(8), 856–862. <https://doi.org/10.47750/pnr.2022.13.S08.108>
- Wahidin, M., Mustikawati, I. S., Handayani, R., & Letelay, A. M. (2025). *Gambaran Prevalensi Hipertensi dan Faktor Risiko Utama di Indonesia – Analisis Data Tingkat Kabupaten / Kota Overview of Hypertension Prevalence and Its Main Risk Factors in Indonesia – a District-Level Data Analysis*. 9(3), 438–442. <https://doi.org/10.20473/amnt.v9i3.2025.438-442>