



Pengembangan Intelligent Expert System Berbasis Machine Learning untuk Diagnosa Penyakit Jantung Menggunakan Algoritma Random Forest

Development of a Machine Learning-Based Intelligent Expert System for Heart Disease Diagnosis Using the Random Forest Algorithm

Fendri Martadinata¹, A. Firdaus², Gusnaini³

Prodi Sistem Informasi, Universitas Muhammadiyah Ahmad Dahlan Palembang

*Korespondensi e-mail : fendriweb@gmail.com,

Abstract

Heart disease is one of the leading causes of death worldwide and requires prompt and accurate diagnosis to reduce the risk of severe complications. Conventional diagnostic processes that rely heavily on manual analysis often take considerable time and may lead to errors, especially when handling large and complex patient data. Therefore, an intelligent system is needed to assist in the diagnostic process in a more efficient and automated manner. This study aims to develop an intelligent expert system based on machine learning for heart disease diagnosis using the Random Forest algorithm. The dataset used in this study was obtained from a public Kaggle repository and originally consisted of 1,025 records with 13 attributes; however, duplicate-record checking revealed that 723 rows (about 70%) were duplicates of a smaller source, leaving 302 unique patient records after cleaning. The cleaned data were divided into training and testing sets using an 80:20 ratio, resulting in 241 training records and 61 testing records. The research methodology includes duplicate removal, data preprocessing, model training using the Random Forest algorithm with 5-fold cross-validation, and performance evaluation using accuracy, precision, recall, and F1-score metrics. The experimental results show that the proposed model achieves a test accuracy of 77.05% (5-fold cross-validation mean of $82.48\% \pm 4.88\%$), with precision, recall, and F1-score of approximately 0.79. Furthermore, the confusion matrix analysis indicates that the model correctly classified 21 negative cases and 26 positive cases out of 61 testing records. These results, which are consistent with accuracy levels reported in related studies (82-93%), demonstrate that the Random Forest algorithm has reasonable capability in identifying data patterns once data leakage from duplicated records is eliminated. Therefore, the developed system can be utilized as a supportive tool for early detection of heart disease in a more effective, accurate, and efficient manner.

Keywords: Expert System, Machine Learning, Random Forest, Disease Diagnosis

Abstrak

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia dan memerlukan penanganan yang cepat serta diagnosis yang akurat untuk mengurangi risiko komplikasi yang lebih serius. Proses diagnosis yang masih bergantung pada analisis manual seringkali membutuhkan waktu yang cukup lama dan berpotensi menimbulkan kesalahan, terutama ketika jumlah data pasien semakin besar dan kompleks. Oleh karena itu, diperlukan suatu sistem cerdas yang mampu membantu proses diagnosis secara otomatis dan efisien. Penelitian ini bertujuan untuk mengembangkan *intelligent expert system* berbasis *machine learning* untuk mendiagnosa penyakit jantung dengan memanfaatkan algoritma Random Forest. Dataset yang digunakan diperoleh dari repositori publik Kaggle dan awalnya berjumlah 1.025 data pasien dengan 13 atribut yang menggambarkan kondisi kesehatan. Namun, pemeriksaan data duplikat menunjukkan bahwa 723 baris (sekitar 70%) merupakan duplikat, sehingga tersisa 302 data unik setelah dibersihkan. Data bersih tersebut dibagi menjadi data latih sebanyak 241 data dan data uji sebanyak 61 data menggunakan metode *train-test split* dengan rasio 80:20. Tahapan penelitian meliputi pembersihan data duplikat, proses *preprocessing* data, pelatihan model menggunakan algoritma Random Forest disertai validasi 5-fold cross-validation, serta evaluasi performa model menggunakan metrik akurasi, presisi, recall, dan f1-score. Hasil pengujian menunjukkan bahwa model yang dikembangkan mencapai akurasi data uji sebesar 77,05% (rata-rata 5-fold cross-validation sebesar $82,48\% \pm 4,88\%$), dengan nilai presisi, recall, dan f1-score masing-masing sekitar 0,79. Analisis *confusion matrix* menunjukkan bahwa sistem mampu mengklasifikasikan 21 data negatif dan 26 data positif dengan benar dari 61 data uji. Hasil ini, yang sejalan dengan tingkat akurasi pada penelitian terkait (82-93%), menunjukkan bahwa algoritma Random Forest memiliki kemampuan yang baik dalam mengenali pola data setelah risiko kebocoran data akibat duplikasi dihilangkan. Dengan demikian, sistem yang dikembangkan dapat dimanfaatkan sebagai alat bantu dalam mendukung deteksi dini penyakit jantung secara lebih efektif, akurat, dan efisien.

Kata Kunci: Sistem Pakar, Machine Learning, Random Forest, Diagnosa Penyakit

1. Pendahuluan

Secara global, penyakit jantung masih menjadi salah satu penyebab utama kematian dengan kontribusi yang sangat besar terhadap angka mortalitas dunia. Data dari *World Health Organization* menunjukkan bahwa setiap tahun sekitar 17,9 juta kematian disebabkan oleh penyakit kardiovaskular, atau setara dengan hampir sepertiga dari total kematian global [1]. Fakta ini menegaskan bahwa penyakit jantung merupakan permasalahan kesehatan yang memerlukan perhatian serius, baik pada tingkat global maupun nasional. Di Indonesia, jumlah penderita penyakit jantung juga terus mengalami peningkatan yang dipengaruhi oleh berbagai faktor risiko, seperti pola hidup tidak sehat [2], kurangnya aktivitas fisik, serta meningkatnya prevalensi obesitas, hipertensi [3], dan diabetes mellitus [4]. Selain itu, rendahnya kesadaran masyarakat terhadap pentingnya deteksi dini turut memperburuk kondisi tersebut.

Permasalahan utama dalam penanganan penyakit jantung terletak pada keterlambatan diagnosis. Banyak kasus baru teridentifikasi ketika kondisi pasien sudah berada pada tahap lanjut, sehingga memperbesar risiko komplikasi dan menurunkan peluang keberhasilan pengobatan [5]. Kondisi ini dipengaruhi oleh keterbatasan tenaga medis, terbatasnya fasilitas layanan kesehatan, serta kompleksitas gejala penyakit jantung yang sering kali tidak spesifik. Di samping itu, proses analisis data klinis yang masih dilakukan secara manual berpotensi menimbulkan ketidakkonsistenan dalam interpretasi, terutama ketika data yang dianalisis memiliki jumlah dan variasi yang tinggi.

Untuk mengatasi permasalahan tersebut, pemanfaatan teknologi kecerdasan buatan menjadi salah satu pendekatan yang semakin relevan. Sistem pakar [6] yang dikombinasikan dengan teknik *machine learning* [7] dapat digunakan untuk membantu proses diagnosis secara lebih cepat dan akurat [8]. Sistem pakar modern tidak hanya mengandalkan aturan tetap, tetapi juga mampu belajar dari data historis untuk meningkatkan performa prediksi. Hal ini menjadi keunggulan dibandingkan sistem berbasis aturan (*rule-based*) yang cenderung kurang fleksibel dalam menghadapi data yang kompleks dan dinamis. Salah satu algoritma yang banyak digunakan dalam klasifikasi data medis adalah Random Forest. Algoritma ini termasuk dalam metode *ensemble learning* yang bekerja dengan menggabungkan

sejumlah *decision tree* untuk menghasilkan prediksi yang lebih akurat dan stabil. Keunggulan utama *Random Forest* terletak pada kemampuannya dalam menangani data berdimensi tinggi, mengurangi risiko *overfitting*, serta tetap *robust* terhadap data yang mengandung noise [9]. Selain itu, algoritma ini juga memiliki kemampuan generalisasi yang baik sehingga cocok diterapkan pada data medis yang kompleks.

Sejumlah penelitian sebelumnya menunjukkan bahwa penerapan algoritma *Random Forest* maupun metode *machine learning* lainnya mampu menghasilkan performa yang cukup tinggi dalam diagnosis penyakit jantung, dengan tingkat akurasi yang dilaporkan berkisar antara 82% hingga 93% [10]. Hasil tersebut menunjukkan bahwa pendekatan berbasis data memiliki potensi besar dalam meningkatkan kualitas layanan kesehatan, khususnya dalam proses deteksi dini.

Selain pendekatan berbasis *machine learning*, beberapa penelitian juga memanfaatkan sistem pakar untuk mendeteksi penyakit. Pada penelitian [11], metode *forward chaining* digunakan sebagai mekanisme inferensi simbolik yang memulai proses penalaran dari fakta atau gejala yang dimasukkan oleh pengguna. Pendekatan ini terbukti efektif dalam membantu proses identifikasi penyakit diabetes melitus karena memberikan alur penalaran yang logis, transparan, dan mudah ditelusuri, baik oleh pengguna maupun tenaga medis. Namun, penelitian tersebut juga menunjukkan beberapa keterbatasan, terutama dalam menangani data medis yang kompleks dan bervariasi, karena sistem hanya bergantung pada basis aturan statis yang tidak dapat diperbarui secara otomatis. Hasil uji coba pada penelitian [12] menunjukkan bahwa teknik *forward chaining* mampu menentukan diagnosis diabetes melitus pada remaja dengan tingkat akurasi sebesar 85%.

Sisi lain dari kajian sistem pakar memperlihatkan penggunaan *backward chaining* pada aplikasi berbasis *web* yang ditujukan untuk diagnosis spesifik, contohnya sistem pakar *backward chaining* untuk mendiagnosa penyakit mata pada anak akibat bermain *game online*. Pendekatan *backward chaining* efektif untuk verifikasi hipotesis diagnostik (dari hipotesis ke bukti), cocok untuk kasus yang membutuhkan pertanyaan bertarget dan pemeriksaan aturan yang spesifik; namun penelitian-penelitian tersebut biasanya masih bersifat *rule-centric* tanpa modul pembelajaran otomatis untuk menyesuaikan aturan dengan data empiris baru [13]. [14] Hasil yang dicapai penelitian tentang optimalisasi layanan e-

government adalah sebanyak 21 *Rule* yang dapat diaplikasikan secara langsung pada layanan *helpdesk*, dengan tingkat akurasi sebesar 92%.

Di level *machine-learning* (ML), literatur terbaru menunjukkan kemajuan signifikan pada sistem pendukung keputusan (DSS) berbasis ML untuk deteksi dini gangguan kardiak. Tinjauan *state-of-the-art* melaporkan bahwa rangkaian algoritma *Random Forest* [15] [16] dapat mencapai performa klasifikasi yang sangat baik, beberapa studi melaporkan akurasi >90% pada dataset publik seperti UCI/Statlog/Z-Alizadeh setelah dilakukan pemrosesan data dan optimasi *hyperparameter*.

Berdasarkan hal tersebut, pengembangan sistem pakar cerdas berbasis *machine learning* menjadi langkah yang strategis untuk meningkatkan akurasi diagnosis penyakit jantung. Sistem yang dikembangkan diharapkan mampu membantu tenaga medis dalam melakukan analisis data secara lebih cepat, konsisten, dan akurat. Selain itu, sistem ini juga dapat dimanfaatkan sebagai alat bantu skrining awal, sehingga memungkinkan deteksi penyakit dilakukan lebih dini. Dengan demikian, penerapan teknologi ini diharapkan dapat memberikan kontribusi nyata dalam peningkatan kualitas layanan kesehatan serta menekan angka kematian akibat penyakit jantung.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan memanfaatkan teknik *machine learning* untuk mengembangkan sistem pakar cerdas dalam mendiagnosa penyakit jantung. Metode yang digunakan meliputi beberapa tahapan, yaitu pengumpulan data, *preprocessing*, pembangunan model, serta evaluasi performa model.

Dataset yang digunakan dalam penelitian ini terdiri dari 1.025 data dengan 14 atribut, yang meliputi 13 atribut sebagai variabel input dan 1 atribut sebagai variabel *output*. Atribut *input* mencakup umur, jenis kelamin, nyeri dada, tekanan darah, kolesterol, gula darah puasa, hasil EKG, detak jantung maksimum, angina saat olahraga, depresi ST, kemiringan ST, jumlah pembuluh darah, dan kondisi darah. Sedangkan atribut *output* berupa hasil diagnosis yang digunakan untuk menentukan klasifikasi penyakit jantung. Pemeriksaan lebih lanjut terhadap dataset ini menemukan bahwa dari 1.025 baris data, sebanyak 723 baris (sekitar 70%) merupakan data duplikat, sehingga hanya tersisa 302 data unik. Duplikasi ini kemungkinan besar berasal dari replikasi dataset UCI Heart Disease (Cleveland,

303 data asli) yang beredar di Kaggle. Seluruh analisis dan model pada penelitian ini selanjutnya menggunakan 302 data unik tersebut untuk menghindari kebocoran data (*data leakage*) antara data latih dan data uji.

Tahapan penelitian dilakukan secara sistematis sebagai berikut:

1. Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh dari *platform Kaggle* yang menyediakan berbagai *dataset* terbuka (*open dataset*) di bidang kesehatan. *Dataset* yang digunakan merupakan *dataset* penyakit jantung yang berisi data rekam medis pasien dengan berbagai atribut klinis yang relevan untuk proses diagnosis. Sebelum digunakan, dilakukan pemeriksaan data duplikat menggunakan fungsi *drop_duplicates()*, dan ditemukan 723 dari 1.025 baris data (sekitar 70%) merupakan duplikat, sehingga tersisa 302 data unik. Kondisi ini konsisten dengan versi-versi dataset penyakit jantung di Kaggle yang merupakan replikasi dari dataset UCI Heart Disease. Seluruh baris duplikat dihapus sebelum tahap pembagian data latih dan data uji untuk mencegah data leakage.

2. Preprocessing Data

Pada tahap ini dilakukan pembersihan data (*data cleaning*), penanganan nilai yang hilang (*missing value*), serta normalisasi data jika diperlukan untuk meningkatkan kualitas *dataset*. Secara rinci, pemeriksaan pada dataset ini tidak menemukan adanya nilai yang hilang (*missing value*) pada seluruh 13 atribut, sehingga tidak diperlukan imputasi. Seluruh atribut kategorikal (jenis kelamin, hasil EKG, angina saat olahraga, kemiringan ST, dan kondisi darah) sudah tersedia dalam bentuk numerik terencode pada sumber data sehingga tidak memerlukan encoding tambahan. Tahap pembersihan data yang paling signifikan pada dataset ini adalah penghapusan 723 baris duplikat (dari 1.025 menjadi 302 data unik) sebagaimana dijelaskan pada tahap pengumpulan data, yang dilakukan sebelum tahap pembagian data latih dan data uji untuk mencegah *data leakage*. [17].

3. Pembagian Data


Dataset yang telah bersih dari duplikat (302 data unik) dibagi menjadi data latih dan data uji dengan rasio 80:20 secara stratified untuk memastikan model dapat diuji secara objektif.

Tabel 1. Distribusi Split Dataset

Dataset	Jumlah	Persentase (%)
Training	241	80
Testing	61	20
Total	302	100

4. Pembangunan Model

Model dikembangkan menggunakan algoritma *Random Forest*, yang merupakan metode *ensemble learning* berbasis *decision tree*. Algoritma ini bekerja dengan membangun sejumlah pohon keputusan dan menggabungkan hasilnya untuk meningkatkan akurasi prediksi. Konfigurasi hyperparameter yang digunakan adalah $n_estimators = 100$, $max_depth = 7$, $max_features = 'sqrt'$, dan $random_state = 60$. Untuk memperkuat validitas temuan selain evaluasi pada satu kali pembagian data latih-uji, dilakukan pula validasi tambahan menggunakan 5-fold cross-validation pada seluruh 302 data unik, yang menghasilkan rata-rata akurasi sebesar 82,48% dengan standar deviasi 4,88% antar fold, menunjukkan performa model yang relatif stabil meskipun ukuran dataset terbatas [18].



Gambar 1. Random forest algorithm [19]

5. Evaluasi Model

Evaluasi menggunakan beberapa metrik, yaitu: Akurasi, Presisi, *Recall*, *F1-score* dan *Confusion matrix*. Evaluasi ini bertujuan untuk mengukur kinerja model dalam mengklasifikasikan data secara tepat [20].

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil pengujian serta analisis terhadap model klasifikasi penyakit jantung yang dikembangkan menggunakan algoritma *Random Forest*. Model dibangun berdasarkan *dataset* yang telah melalui tahap

preprocessing dan dibagi menjadi data latih dan data uji untuk memastikan evaluasi yang objektif. Pengujian dilakukan untuk mengukur kinerja model dalam mengklasifikasikan data pasien berdasarkan atribut klinis yang tersedia.

3.1 Hasil Pengujian Model

Berdasarkan hasil pengujian pada gambar 2, model *Random Forest* yang dikembangkan menunjukkan performa yang sangat baik dalam melakukan klasifikasi penyakit jantung. Hal ini ditunjukkan dengan nilai akurasi sebesar 77,05% pada data uji (61 data), dengan rata-rata akurasi 5-fold cross-validation sebesar 82,48% ($\pm 4,88\%$), setelah data duplikat pada dataset dibersihkan terlebih dahulu. Selain itu, berdasarkan *classification report* pada Gambar 2, nilai presisi, *recall*, dan *f1-score* untuk kelas 0 masing-masing sebesar 0,75, sedangkan untuk kelas 1 masing-masing sebesar 0,79. Nilai rata-rata (*macro average* dan *weighted average*) juga menunjukkan hasil yang konsisten, yaitu sebesar 0,77. Hal ini mengindikasikan bahwa setelah risiko data leakage dihilangkan, model tetap mampu melakukan klasifikasi secara cukup stabil dan seimbang pada kedua kelas, meskipun dengan tingkat akurasi yang lebih realistis dibandingkan evaluasi awal pada data yang masih mengandung duplikat.

	precision	recall	f1-score	support
Kelas 0	0.75	0.75	0.75	28.0
Kelas 1	0.79	0.79	0.79	33.0
accuracy	0.77	0.77	0.77	0.77
macro avg	0.77	0.77	0.77	61.0
weighted avg	0.77	0.77	0.77	61.0

Gambar 2. Classification Report

Berdasarkan hasil visualisasi *confusion matrix* pada gambar 3, dapat diketahui bahwa model *Random Forest* yang dikembangkan memiliki kemampuan klasifikasi yang sangat baik. Model berhasil mengklasifikasikan 21 data sebagai kelas negatif (*true negative*) dan 26 data sebagai kelas positif (*true positive*) secara benar. Sementara itu, terdapat 7 data yang diklasifikasikan sebagai *false positive*, yaitu data yang sebenarnya negatif tetapi diprediksi sebagai positif, serta 7 data yang termasuk *false negative*, yaitu data yang sebenarnya positif tetapi diprediksi sebagai negatif. Jumlah kesalahan klasifikasi sebanyak 14 data dari total 61 data uji (setelah dedup), jumlah yang secara proporsional sedikit lebih tinggi dibandingkan hasil evaluasi awal pada data yang masih mengandung duplikat, namun mencerminkan performa model yang lebih jujur dan bebas dari data leakage. Nilai *false negative*


dan *false positive* yang seimbang (masing-masing 7 data) menjadi perhatian dalam konteks medis, karena kesalahan *false negative* berarti pasien yang sebenarnya menderita penyakit jantung tidak terdeteksi oleh model, sehingga perlu diimbangi dengan validasi klinis lanjutan. Secara keseluruhan, hasil *confusion matrix* ini menunjukkan bahwa model memiliki performa yang cukup baik dan lebih realistis setelah dataset dibersihkan dari duplikasi, meskipun masih memerlukan perbaikan lebih lanjut, misalnya melalui penambahan data.



Gambar 3. Confusion Matrix

Berdasarkan hasil visualisasi *feature importance* pada gambar 4 untuk model Random Forest, dapat diketahui bahwa setiap atribut memiliki kontribusi yang berbeda dalam proses klasifikasi penyakit jantung. Atribut nyeri_dada (*chest pain*) memiliki tingkat kepentingan tertinggi, yang menunjukkan bahwa variabel ini menjadi faktor paling dominan dalam menentukan hasil diagnosis. Hal ini sejalan dengan kondisi klinis di mana jenis nyeri dada merupakan indikator utama dalam mendeteksi gangguan jantung. Selanjutnya, atribut detak_jantung_maksimum (*thalach*), depresi_ST (*oldpeak*), jumlah_pembuluh_darah (*ca*), dan kondisi_darah juga menunjukkan nilai kepentingan yang cukup tinggi dan relatif merata. Keempat atribut ini berkaitan dengan kondisi fisiologis jantung dan aliran darah, yang merupakan faktor penting dalam diagnosis penyakit jantung. Atribut angina_saas_olahraga (*exang*), umur (*age*), kolesterol (*chol*), dan tekanan_darah (*trestbps*) memiliki tingkat kepentingan menengah, yang menunjukkan bahwa variabel-variabel tersebut tetap berpengaruh namun tidak dominan dalam proses klasifikasi. Di sisi lain, atribut jenis_kelamin, kemiringan_ST, hasil_EKG, dan gula_darah_puasa memiliki nilai kepentingan yang relatif rendah, sehingga kontribusinya terhadap hasil prediksi model tidak terlalu signifikan. Secara keseluruhan, hasil *feature importance* ini menunjukkan bahwa model *Random Forest* mampu mengidentifikasi atribut-atribut yang

paling berpengaruh dalam diagnosis penyakit jantung. Informasi ini tidak hanya berguna untuk meningkatkan interpretabilitas model, tetapi juga dapat menjadi dasar bagi tenaga medis dalam memahami faktor-faktor utama yang berkontribusi terhadap risiko penyakit jantung.



Gambar 4. Feature Importance

Diagnosa Penyakit Jantung

Umur: 60, Jenis Kelamin (1=L, 0=P): 1
 Nyeri Dada (0-3): 0, Tekanan Darah: 130
 Kolesterol: 250, Gula Darah Puasa (0/1): 0
 Hasil EKG (0-2): 1, Detak Jantung Maksimum: 140
 Angina Saat Olahraga (0/1): 0, Depresi ST: 1.5
 Kemiringan ST (0-2): 2, Jumlah Pembuluh Darah (0-3): 0
 Kondisi Darah (1-3): 2

Terindikasi Penyakit Jantung
 Tingkat Keyakinan: 71.0%

Gambar 5. Hasil Pengujian

Gambar 5 menunjukkan tampilan antarmuka (*user interface*) dari aplikasi sistem pakar berbasis web yang dikembangkan menggunakan *framework Flask* untuk melakukan diagnosa penyakit jantung. Aplikasi ini dirancang dalam bentuk *form input* yang memungkinkan pengguna memasukkan berbagai parameter klinis pasien sebagai dasar dalam proses prediksi. Parameter yang dimasukkan meliputi umur, jenis kelamin, nyeri dada, tekanan darah, kadar kolesterol, gula darah puasa, hasil EKG, detak jantung maksimum, angina saat olahraga, depresi ST, kemiringan ST, jumlah

pembuluh darah, serta kondisi darah. Setiap atribut tersebut merepresentasikan fitur yang digunakan dalam model *machine learning* yang telah dilatih sebelumnya menggunakan algoritma *Random Forest*.

Setelah seluruh data diinputkan, pengguna dapat menekan tombol “Prediksi” untuk menjalankan proses klasifikasi. Sistem kemudian memproses data tersebut melalui model yang telah diimplementasikan pada *backend Flask* dan menghasilkan output berupa hasil diagnosis, yaitu apakah pasien terindikasi penyakit jantung atau tidak, beserta tingkat keyakinan (*confidence score*) dari prediksi yang dihasilkan diperoleh *output* berupa “Terindikasi Penyakit Jantung” dengan tingkat keyakinan sebesar 71,0%. Hasil ini menunjukkan bahwa model *Random Forest* yang digunakan dalam sistem memprediksi bahwa data pasien yang diinput memiliki kecenderungan mengarah pada kondisi penyakit jantung. Nilai *confidence score* tersebut mengindikasikan bahwa model memiliki tingkat kepercayaan yang cukup tinggi terhadap hasil klasifikasi yang diberikan. Perlu ditegaskan bahwa contoh hasil prediksi pada Gambar 5 ini berasal dari satu kasus uji tunggal pada antarmuka aplikasi untuk mengilustrasikan cara kerja sistem, bukan merupakan bukti kinerja model secara umum. Metrik kinerja model yang sebenarnya, seperti akurasi, presisi, recall, dan f1-score, telah dilaporkan secara terpisah pada Tabel dan Gambar sebelumnya.

Interpretasi nilai probabilitas ini menunjukkan bahwa dari keseluruhan pohon keputusan (*decision tree*) dalam algoritma *Random Forest*, sebagian besar memberikan hasil prediksi pada kelas positif (penyakit jantung). Semakin tinggi nilai probabilitas yang dihasilkan, maka semakin besar tingkat keyakinan model terhadap prediksi tersebut. Namun demikian, nilai ini tetap perlu dipertimbangkan sebagai alat bantu keputusan, bukan sebagai diagnosis final, sehingga tetap memerlukan validasi lebih lanjut oleh tenaga medis profesional.

Hasil ini menunjukkan bahwa sistem yang dikembangkan mampu memberikan prediksi secara *real-time* dan dapat digunakan sebagai alat bantu dalam mendukung deteksi dini penyakit jantung. Dengan adanya informasi tingkat keyakinan, pengguna juga dapat memperoleh gambaran tingkat risiko yang lebih jelas terhadap kondisi yang dialami.

3.2 Pembahasan

Hasil penelitian ini menunjukkan bahwa algoritma *Random Forest* memiliki kemampuan

yang sangat baik dalam melakukan klasifikasi penyakit jantung. Hal ini ditunjukkan oleh tingginya nilai akurasi serta keseimbangan antara presisi dan *recall*, yang mengindikasikan bahwa model mampu mengklasifikasikan data secara tepat sekaligus meminimalkan kesalahan prediksi. Keseimbangan tersebut juga mencerminkan bahwa model memiliki performa yang stabil dan dapat diandalkan dalam membedakan antara kelas positif dan negatif.

Keunggulan utama *Random Forest* terletak pada kemampuannya dalam menggabungkan sejumlah *decision tree* melalui pendekatan *ensemble learning*, sehingga mampu mengurangi risiko *overfitting* dan meningkatkan kemampuan generalisasi terhadap data baru. Selain itu, algoritma ini efektif dalam menangani data berdimensi tinggi serta data yang mengandung *noise*, yang umum ditemukan pada dataset medis. Kemampuan ini menjadikan *Random Forest* sebagai salah satu metode yang sesuai untuk permasalahan klasifikasi di bidang kesehatan.

Setelah dataset dibersihkan dari duplikasi, hasil rata-rata 5-fold cross-validation dalam penelitian ini (82,48%) berada pada rentang yang sebanding dengan penelitian sebelumnya, yang umumnya menghasilkan tingkat akurasi berkisar antara 82% hingga 93%. Perbandingan ini bersifat deskriptif dan belum didukung oleh uji statistik formal (misalnya uji signifikansi antar model atau interval kepercayaan), serta dataset, jumlah sampel, dan skema pembagian data yang berbeda antar penelitian membuat perbandingan langsung ini memiliki keterbatasan. Oleh karena itu, hasil penelitian ini lebih tepat dimaknai sebagai performa yang sebanding, bukan sebagai peningkatan yang signifikan secara statistik, dibandingkan penelitian-penelitian terkait.

Lebih lanjut, hasil evaluasi melalui *confusion matrix* menunjukkan bahwa jumlah kesalahan klasifikasi sebanding antara *false negative* dan *false positive* (masing-masing 7 data dari 61 data uji). Hal ini menjadi aspek penting dalam konteks medis, karena kesalahan dalam mengidentifikasi pasien yang benar-benar menderita penyakit jantung (*false negative*) dapat berdampak serius. Dengan demikian, model yang dikembangkan memiliki potensi yang cukup baik untuk digunakan sebagai alat bantu awal dalam mendukung proses diagnosis, dengan tetap memerlukan validasi klinis lebih lanjut.

Secara keseluruhan, sistem pakar berbasis *machine learning* yang dikembangkan dalam penelitian ini dapat dimanfaatkan sebagai alat bantu dalam proses diagnosis penyakit jantung. Sistem ini tidak hanya mampu memberikan prediksi secara cepat dan akurat, tetapi juga dapat mendukung

tenaga medis dalam pengambilan keputusan serta meningkatkan efektivitas deteksi dini penyakit jantung.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma *Random Forest* dalam pengembangan *intelligent expert system* untuk diagnosis penyakit jantung menunjukkan performa yang cukup baik setelah dataset dibersihkan dari duplikasi. Dataset awal yang berjumlah 1.025 data ternyata mengandung 723 baris duplikat, sehingga model dibangun menggunakan *dataset* bersih sebanyak 302 data unik dengan 13 atribut, dan berhasil mencapai tingkat akurasi sebesar 77,05% pada data uji (rata-rata 5-fold cross-validation sebesar 82,48% $\pm$ 4,88%), dengan nilai presisi, *recall*, dan *f1-score* masing-masing sekitar 0,79. Hasil evaluasi melalui *confusion matrix* juga menunjukkan bahwa model memiliki tingkat kesalahan klasifikasi yang wajar dan lebih realistis dibandingkan evaluasi awal pada data yang masih mengandung duplikat, sehingga mampu memberikan prediksi yang cukup akurat dan dapat diandalkan sebagai alat bantu awal.

Selain itu, analisis *feature importance* menunjukkan bahwa atribut nyeri dada, kondisi darah, dan jumlah pembuluh darah merupakan faktor yang paling berpengaruh dalam proses klasifikasi penyakit jantung. Temuan ini menunjukkan bahwa model tidak hanya memiliki kinerja yang tinggi, tetapi juga mampu mengidentifikasi variabel penting yang relevan secara klinis.

Penelitian ini juga memiliki beberapa keterbatasan yang perlu diperhatikan pada penelitian lanjutan: (1) evaluasi hanya dilakukan pada satu kali *train-test split* selain 5-fold cross-validation, pada dataset publik yang setelah dibersihkan hanya berjumlah 302 data unik; (2) belum ada validasi eksternal pada dataset atau populasi klinis independen di luar sumber Kaggle/UCI yang digunakan; dan (3) belum ada uji coba dengan pengguna nyata (tenaga medis) untuk menilai kegunaan sistem secara praktis di lapangan. Penelitian lanjutan disarankan untuk menggunakan dataset dengan jumlah sampel yang lebih besar dan beragam, melibatkan validasi klinis oleh tenaga medis, serta melaporkan interval kepercayaan atau uji statistik saat membandingkan performa dengan penelitian lain, guna memperkuat kredibilitas klaim performa sistem.

Secara keseluruhan, sistem pakar berbasis *machine learning* yang dikembangkan dalam penelitian ini berpotensi untuk digunakan sebagai alat bantu dalam mendukung deteksi dini penyakit

jantung secara cepat, akurat, dan efisien. Implementasi sistem ini diharapkan dapat membantu tenaga medis dalam pengambilan keputusan serta meningkatkan kualitas layanan kesehatan berbasis teknologi.

Ucapan Terima Kasih

Terima kasih kepada semua pihak yang terkait dalam penelitian dan Universitas Muhammadiyah Ahmad Dahlan Palembang.

Daftar Rujukan

- [1] F. Febby, A. Arjuna, and M. Maryana, "Dukungan Keluarga Berhubungan dengan Kualitas Hidup Pasien Gagal Jantung," *J. Penelit. Perawat Prof.*, vol. 5, no. 2, pp. 691–702, Mar. 2023, doi: 10.37287/jppp.v5i2.1537.
- [2] Irfan Sazali Nasution, Arini Dwi Rahmadani, W. Audina, D. P. Sari, and N. D. Sari, "Systematic Review: Pengaruh Gaya Hidup dan Pengetahuan Masyarakat terhadap Risiko Penyakit Jantung Koroner," *Sehat Rakyat J. Kesehat. Masy.*, vol. 4, no. 2, pp. 287–298, May 2025, doi: 10.54259/sehatrakyat.v4i2.4337.
- [3] M. Ardiana, N. I. Intansari, and A. N. Fadila, "The Consequences of Hypertension and Obesity on Coronary Heart Disease," *Pharmacogn. Journal*, vol. 16, no. 6, pp. 1331–1335, Jan. 2025, doi: 10.5530/pj.2024.16.214.
- [4] Cindy Muazizah and Hermina Novida, "Faktor Risiko Kematian Pada Pasien Diabetes Melitus dan Penyakit Jantung: Systematic Review," *J. Ilmu Kedokt. dan Kesehat. Indones.*, vol. 4, no. 2, pp. 01–13, Jul. 2024, doi: 10.55606/jikki.v4i2.3908.
- [5] Y. Muhammad, M. Tahir, M. Hayat, and K. T. Chong, "Early and accurate detection and diagnosis of heart disease using intelligent computational model," *Sci. Rep.*, vol. 10, no. 1, p. 19747, Nov. 2020, doi: 10.1038/s41598-020-76635-9.
- [6] Linda Marlinda, *Sistem Pakar Perancangan dan Pembahasan Metode Chaining, Certainty Faktor, Fuzzy Logik*, Pertama. Yogyakarta: Graha Ilmu, 2021.
- [7] A. A. Panji Bintoro, Ratnasari, Edy Wihardjo, Indah Pratiwi Putri, *Pengantar Machine Learning*, Pertama. Sumatera Barat: PT Mafy Media Literasi Indonesia, 2024.
- [8] S. B. Abbasi, S. U. Rehman, K. Aziz, M. A. Abid, and S. W. Lee, "Early diagnosis of

- cardiac disorders using machine learning-based decision support system,” *Precis. Futur. Med.*, vol. 9, no. 2, pp. 77–91, Jun. 2025, doi: 10.23838/pfm.2025.00142.
- [9] Soumya K S and Alias Itten, “Heart Disease Prediction Using Random Forest Algorithm: A Comprehensive Analysis,” *Int. J. Eng. Res. Sci. Technol.*, vol. 22, no. 2, pp. 119–123, Apr. 2025, doi: 10.62643/ijerst.2025.v21.i2.p119-123.
- [10] A. Handayani, S. Salsabila, A. Firdausiyah, A. Setiawan, and Y. Nia Nesicha, “Predictive Analysis Heart Disease Based on Machine Learning Using the Random Forest Algorithm,” *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 3, pp. 1980–1986, Jun. 2025, doi: 10.59934/jaiea.v4i3.1060.
- [11] D. Ayu Puspita Sari, A. Suradi, and M. Windarti, “SISTEM PAKAR DIAGNOSA KESEHATAN MENTAL PADA REMAJA DENGAN METODE FORWARD CHAINING BERBASIS WEB,” *J. Comput. Sci. Technol.*, vol. 4, no. 2, pp. 34–39, Nov. 2024, doi: 10.54840/jcstech.v4i2.309.
- [12] D. Supiyan, “Pengembangan Sistem Pakar Untuk Diagnosa Penyakit Diabetes Melitus Menggunakan Metode Forward Chaining,” *bit-Tech*, vol. 7, no. 3, pp. 918–927, Apr. 2025, doi: 10.32877/bt.v7i3.2244.
- [13] R. S. Abbrar, M. Eka, and I. Rusydi, “Sistem Pakar Backward Chaining Untuk Mendiagnosa Penyakit Mata Pada Anak Akibat Bermain Game Online Berbasis Web,” *War. Dharmawangsa*, vol. 19, no. 1, pp. 488–501, Jan. 2025, doi: 10.46576/wdw.v19i1.5883.
- [14] L. H. E-government and P. Hariona, “Jurnal Informatika Ekonomi Bisnis Sistem Pakar dengan Metode Backward Chaining untuk Optimalisasi,” vol. 3, pp. 66–71, 2021, doi: 10.37034/infeb.v3i2.68.
- [15] M. Pal and S. Parija, “Prediction of Heart Diseases using Random Forest,” *J. Phys. Conf. Ser.*, vol. 1817, no. 1, p. 012009, Mar. 2021, doi: 10.1088/1742-6596/1817/1/012009.
- [16] Ersu Muliani, Asmarani Ayudhia, Maulidya, Novan Alkaf Bahraini Saputra, and Nuruddin Wiranda, “Implementasi Algoritma Random Forest dengan Variasi Parameter $n_{estimators}$ untuk Klasifikasi Penyakit Hati,” *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 10, no. 2, pp. 563–571, Jul. 2025, doi: 10.24114/cess.v10i2.66740.
- [17] B. Aribowo, B. Tjahjono, G. Firmansyah, and A. M. Widodo, “Prediksi Peringkat Akreditasi BAN PT Program Studi Sarjana Rumpun Ilmu Komputer Menggunakan Klasifikasi Machine Learning,” *J. AL-AZHAR Indones. SERI SAINS DAN Teknol.*, vol. 10, no. 2, p. 122, May 2025, doi: 10.36722/sst.v10i2.3089.
- [18] Z. Jin, J. Shang, Q. Zhu, C. Ling, W. Xie, and B. Qiang, “RFRSF: Employee Turnover Prediction Based on Random Forests and Survival Analysis,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12343 LNCS, pp. 503–515, 2020, doi: 10.1007/978-3-030-62008-0_35.
- [19] A. Mohanty and G. Gao, “A survey of machine learning techniques for improving Global Navigation Satellite Systems,” *EURASIP J. Adv. Signal Process.*, vol. 2024, no. 1, pp. 1–52, 2024, doi: 10.1186/s13634-024-01167-7.
- [20] D. S. Nurrochmah, N. Rahaningsih, R. D. Dana, and C. L. Rohmat, “Penerapan Algoritma Naive Bayes dalam Analisis Sentimen Ulasan Aplikasi KitaLulus di Google Play Store,” *J. Inform. Terpadu*, vol. 11, no. 1, pp. 1–11, Mar. 2025, doi: 10.54914/jit.v11i1.1544.