

# Analisis Perbandingan Model Machine Learning menggunakan Teknik Stratified K-Fold Cross Validation untuk Klasifikasi Penyakit Jantung

Avrilyan Putra Bintang Pratama\*, Wahyu Aji Eko Prabowo

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: <sup>1</sup>111202214245@mhs.dinus.ac.id, <sup>2</sup>prabowo@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202214245@mhs.dinus.ac.id

Submitted 31-03-2026; Accepted 27-04-2026; Published 30-04-2026

## Abstrak

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia. Pendekatan konvensional masih memiliki keterbatasan, seperti subjektivitas interpretasi dan waktu analisis yang relatif lama. Oleh karena itu, penelitian ini mengusulkan pemanfaatan machine learning untuk meningkatkan akurasi prediksi risiko penyakit jantung dengan membandingkan kinerja algoritma Random Forest, Support Vector Machine (SVM), dan K-Nearest Neighbor (KNN). Metode penelitian meliputi tahap preprocessing data, pembagian data latih dan data uji, serta optimasi hyperparameter menggunakan Stratified K-Fold Cross Validation dengan variasi K = 5, 10, 15, dan 20. Evaluasi model dilakukan menggunakan metrik accuracy, precision, recall, F1-score, dan ROC-AUC untuk mengukur performa klasifikasi secara komprehensif dan objektif. Hasil penelitian menunjukkan bahwa Random Forest memberikan performa terbaik. Pada konfigurasi optimal K=15, model ini mencapai akurasi 93,17%, precision 0,92, recall 0,95, F1-score 0,94, serta ROC-AUC sebesar 0,97. Selain itu, model ini mampu meminimalkan kesalahan klasifikasi, terutama pada False Negative, sehingga lebih efektif dalam mendeteksi pasien berisiko. Kontribusi utama penelitian ini adalah menunjukkan bahwa kombinasi Random Forest dan Stratified K-Fold Cross Validation mampu meningkatkan kinerja klasifikasi secara signifikan serta menghasilkan model yang akurat, stabil, dan andal untuk diimplementasikan dalam sistem pendukung keputusan medis.

**Kata Kunci:** Penyakit Jantung; Klasifikasi; Random Forest; Support Vector Machine; K-Nearest Neighbor

## Abstract

Heart disease is one of the leading causes of death worldwide. Conventional approaches still have limitations, such as subjectivity in interpretation and relatively long analysis times. Therefore, this study proposes using machine learning to improve the accuracy of heart disease risk prediction by comparing the performance of Random Forest, Support Vector Machine (SVM), and K-Nearest Neighbor (KNN) algorithms. The research methodology includes data preprocessing, splitting the dataset into training and testing sets, and hyperparameter optimization using Stratified K-Fold Cross Validation with variations of K = 5, 10, 15, and 20. Model evaluation is conducted using accuracy, precision, recall, F1-score, and ROC-AUC metrics to comprehensively and objectively measure classification performance. The results show that the Random Forest algorithm achieves the best performance. At the optimal configuration of K = 15, the model attains an accuracy of 93.17%, a precision of 0.92, a recall of 0.95, an F1-score of 0.94, and an ROC-AUC of 0.97. In addition, this model minimizes classification errors, particularly False Negatives, making it more effective at identifying at-risk patients. The main contribution of this study is demonstrating that the combination of Random Forest and Stratified K-Fold Cross Validation can significantly improve classification performance and produce a model that is accurate, stable, and reliable for implementation in medical decision support systems.

**Keywords:** Heart Disease; Classification; Random Forest; Support Vector Machine; K-Nearest Neighbor

## 1. PENDAHULUAN

Jantung adalah organ vital yang berfungsi sebagai pemompa darah untuk memenuhi kebutuhan oksigen dan nutrisi ke seluruh tubuh. Gangguan pada fungsi jantung dapat menyebabkan terganggunya sistem peredaran darah, sehingga menjaga kesehatan jantung menjadi sangat penting untuk mencegah berbagai jenis penyakit jantung [1]. Penyakit jantung kerap disebut sebagai *silent killer* karena dalam banyak kasus penderita tidak menyadari kondisinya hingga muncul gejala serius seperti serangan jantung atau gagal jantung, sehingga deteksi dini menjadi sangat penting [2]. Berdasarkan data Badan Kesehatan Dunia (WHO) pada tahun 2016, sebanyak 73% dari total kematian di Indonesia disebabkan oleh penyakit tidak menular, dengan penyakit jantung koroner sebagai penyebab utama sebesar 35% [3]. Fenomena meningkatnya penderita jantung di usia produktif (20-50 tahun) sangat mengkhawatirkan karena berdampak pada produktivitas nasional. Pola konsumsi makanan cepat saji, paparan polusi, serta tingginya tingkat stres di perkotaan menjadi pemicu utama yang mempercepat kerusakan fungsi kardiovaskular pada kelompok usia yang lebih muda. Mengingat situasi yang memprihatinkan ini, diperlukan penelitian lebih lanjut mengenai intervensi yang diberikan untuk mengatasi masalah tersebut, baik dari segi psikologis maupun fisik. Oleh karena itu, dilakukan edukasi yang sangat berkaitan dengan peningkatan kualitas hidup pasien dalam menjalani kehidupan sehari-hari, terutama pada pasien yang sudah menerima diagnosis

Penyakit jantung merupakan salah satu masalah kesehatan utama yang menjadi fokus berbagai penelitian dalam bidang medis dan teknologi kesehatan. Menurut Sari dkk. [4] penelitian yang telah dilakukan dalam bidang ini meliputi berbagai teknologi dan metode, seperti penggunaan data medis, pemodelan matematika, dan pengembangan teknologi diagnostik dan terapeutik. Melalui pengembangan teknologi dan penelitian lebih lanjut, diharapkan dapat meningkatkan pemahaman kita tentang penyakit jantung. Di masa kini dimana ilmu pengetahuan berkembang sangat cepat, para dokter dan tenaga medis yang berkompeten di bidang penyakit jantung telah mengumpulkan banyak informasi mengenai cara mendiagnosis penyakit jantung pada pasien melalui berbagai pengamatan dan penelitian yang telah mereka lakukan [5]. Kekayaan data medis ini kini tersimpan dalam *database* rumah sakit dan lembaga riset, mencakup rekam medis

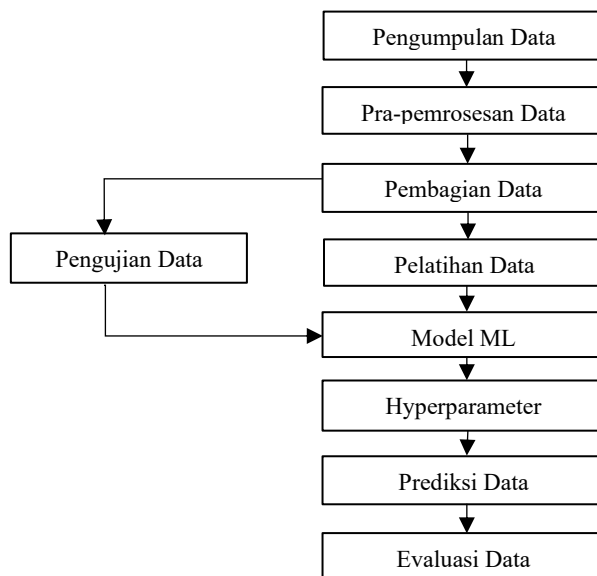
elektronik, hasil pencitraan, hingga profil genetik pasien. Namun, volume data yang sangat besar (*big data*) memerlukan alat bantu yang lebih canggih daripada sekadar analisis statistik konvensional untuk menemukan korelasi yang tidak terlihat secara kasat mata. *Artificial intelligence* (AI) hadir sebagai alternatif dalam bidang ini untuk mendeteksi dan mengklasifikasi penyakit jantung. Sejalan dengan perkembangan tersebut, pendekatan berbasis AI mulai dimanfaatkan untuk mengolah data medis secara sistematis agar dapat menghasilkan prediksi yang lebih cepat dan konsisten sebagai dukungan pengambilan keputusan medis.

Untuk itu penelitian ini menggunakan AI melalui pendekatan *machine learning* (ML) menggunakan dataset berisi 1.943 catatan pasien dengan 11 fitur deskriptor dan satu fitur target. Fitur deskriptor terdiri atas fitur numerik dan fitur kategorikal. Fitur-fitur numerik meliputi usia, tipe nyeri dada, tekanan darah saat istirahat, tekanan darah saat puasa, kolesterol, frekuensi detak jantung maksimal, serta *Oldpeak*. Selain itu, ada fitur kategorikal seperti jenis kelamin, nyeri dada saat berolahraga, hasil EKG saat istirahat, dan kemiringan ST. Fitur target pada penelitian ini adalah *HeartDisease* yang menunjukkan apakah pasien menderita penyakit jantung, dengan nilai 1 artinya positif dan 0 artinya negatif [6],[7].

Penelitian ini menggunakan tiga model ML, yaitu metode *K-Nearest Neighbor* (K-NN), *Support Vector Machine* (SVM), dan *Random Forest* (RF). Berdasarkan penelitian yang telah dilakukan oleh Ryfai dkk [5], metode *K-Nearest Neighbor* (K-NN) menunjukkan tingkat akurasi sebesar 88,33% pada K bernilai 5 Selanjutnya penelitian sebelumnya yang dilakukan oleh Dharmawan dkk [8],[9], menggunakan *Support Vector Machine* (SVM) yang mengkombinasikan SVM dengan *Particle Swarm Optimization* (PSO) berhasil mencapai akurasi sebesar 84,81% pada klasifikasi penyakit jantung. Dan pada penelitian sebelumnya yang dilakukan oleh Tamba dkk. [10], proses implementasi algoritma *Random Forest* berhasil mencapai tingkat akurasi sebesar 82,61%. Selanjutnya, dengan menggunakan metode *Random Forest* yang dioptimasi menggunakan *K-Fold* dan *GridSearchCV*, menghasilkan akurasi yang meningkat menjadi 85,058%. Meskipun berbagai penelitian telah menunjukkan hasil yang cukup baik, masih terdapat keterbatasan dalam hal stabilitas model dan kemampuan generalisasi, terutama karena belum optimalnya penerapan teknik validasi yang mampu menjaga distribusi data secara seimbang pada setiap fold. Selain itu, perbandingan kinerja antar algoritma dengan pendekatan validasi yang konsisten juga masih belum banyak dilakukan secara komprehensif. Berdasarkan hal tersebut, terdapat *research gap* berupa belum optimalnya penerapan teknik validasi yang tepat dalam meningkatkan kinerja dan stabilitas model klasifikasi penyakit jantung. Oleh karena itu, penelitian ini bertujuan untuk membandingkan kinerja algoritma KNN, SVM, dan *Random Forest* dengan optimasi *hyperparameter* menggunakan teknik *Stratified K-Fold Cross Validation*. Kontribusi utama penelitian ini adalah memberikan analisis komparatif yang komprehensif dengan pendekatan validasi yang lebih kuat serta menunjukkan bahwa kombinasi *Random Forest* dan *Stratified K-Fold Cross Validation* mampu meningkatkan akurasi dan stabilitas model secara signifikan.

## 2. METODOLOGI PENELITIAN

Gambar 1 menampilkan tahapan penelitian. Tahapan penelitian dimulai dari pengumpulan data yang relevan, kemudian dilanjutkan dengan pra-pemrosesan data untuk membersihkan dan menyiapkan data agar siap digunakan. Setelah itu, data dibagi menjadi data pelatihan dan data pengujian.



**Gambar 1.** Tahapan penelitian

Data pelatihan digunakan dalam proses pelatihan model *machine learning* untuk membangun model yang optimal, termasuk penyesuaian *hyperparameter* guna meningkatkan kinerja model. Sementara itu, data pengujian digunakan untuk menguji performa model yang telah dilatih. Selanjutnya, model yang telah terbentuk digunakan untuk melakukan prediksi

terhadap data, dan hasil prediksi tersebut dievaluasi untuk menilai tingkat akurasi dan efektivitas model dalam menyelesaikan permasalahan yang diteliti.

## 2.1 Pengumpulan Data

Tahapan penelitian diawali dengan proses pengumpulan dataset yang bersumber dari platform Kaggle [11],[12]. Dataset pertama terdiri dari 918 baris data dengan 12 fitur, sedangkan dataset kedua terdiri dari 1.025 baris data dengan 14 fitur. Selanjutnya dilakukan proses *data merging* atau integrasi data. Proses ini bertujuan untuk menggabungkan dua sumber data yang saling melengkapi agar analisis dapat dilakukan secara lebih komprehensif. Tabel 1 menampilkan hasil penggabungan dan penyesuaian kedua dataset.

**Tabel 1.** Deskripsi fitur dataset jantung

Fitur	Keterangan	Variabel	Rentang Nilai
Age	Umur	Numerik	(28,77)
Sex	Jenis Kelamin	Kategori	F atau M
Chest Pain Type	Nyeri dada	Kategori	ATA,ASY, atau NAP
Resting BP	Tekanan darah	Numerik	(0, 200)
Cholesterol	Kolesterol	Numerik	(0, 603)
Fasting BS	Gula darah	Numerik	[0, 1]
Resting ECG	Elektrokardiogram	Kategori	ST, LVH, atau Normal
Max HR	Detak jantung maksimum	Numerik	(60, 202)
Exercise Angina	Angina latihan	Kategori	Y atau N
Oldpeak	Depresi ST	Numerik (Float)	(-2.6, 6.2)
ST Slope	Kemiringan latihan	Kategori	Up, Down, atau flat
Heart Disease	Kelas gagal jantung	Numerik	[0, 1]

Tabel 1 menunjukkan fitur pada dataset yang terdiri dari 12 fitur yang mempresentasikan kondisi medis pasien terkait penyakit jantung, meliputi *Age* sebagai umur pasien, *Sex* sebagai jenis kelamin, *Chest Pain Type* sebagai nyeri dada, *Resting BP* sebagai tekanan darah saat istirahat, *Cholesterol* sebagai kadar kolesterol, *Fasting BS* sebagai indikator gula darah puasa, *Resting ECG* sebagai elektrokardiogram, *Max HR* sebagai detak jantung maksimum, *Exercise Angina* sebagai indikator angina saat Latihan, *Oldpeak* sebagai nilai depresi segmen ST, serta *ST Slope* sebagai kemiringan segmen ST selama Latihan, dengan *Heart Disease* sebagai *variable target* yang menunjukkan keberadaan penyakit jantung dengan nilai 0 untuk tidak mengalami dan 1 untuk mengalami penyakit jantung.

## 2.2 Preprocessing Data

*Preprocessing* menjadi tahap awal dalam klasifikasi teks untuk mempersiapkan data teks sebelum digunakan pada proses lainnya. Pada tahap ini akan mengubah data teks menjadi bentuk yang lebih baik sehingga menghasilkan informasi teks dengan kualitas yang baik dan siap digunakan pada proses selanjutnya [13]. Langkah pertama adalah menggabungkan dua buah dataset serta melakukan penyesuaian nama kolom untuk menghindari inkonsistensi penulisan, kemudian dilanjutkan dengan pemeriksaan kelengkapan data untuk mengidentifikasi adanya nilai yang hilang pada setiap atribut. Selain itu, dilakukan analisis distribusi data, khususnya pada target, serta pemisahan atribut menjadi fitur numerik dan kategorikal. Selanjutnya, dilakukan proses konversi tipe data, di mana atribut numerik diubah ke dalam format numerik dan atribut kategorikal diubah menjadi tipe string agar dapat diproses lebih lanjut dalam tahapan berikutnya. Dengan tahapan *preprocessing* tersebut, data menjadi lebih terstruktur, konsisten, dan siap digunakan dalam proses pembangunan model klasifikasi penyakit jantung.

## 2.3 Pembagian Data

Split data merupakan evaluasi sederhana yang digunakan dalam proses pembelajaran mesin dengan cara membagi dataset dibagi menjadi dua bagian, yaitu data latih dan data uji. Data latih digunakan untuk membuat dan melatih model, sedangkan data uji digunakan untuk mengetahui sejauh mana model bisa bekerja dengan data yang belum pernah dilihat sebelumnya. Data uji terpisah dan benar-benar terisolasi sehingga tidak ikut dalam proses pelatihan *model machine learning*. Hal ini untuk mencegah terjadinya *data leakage*. Rasio pembagian yang biasa digunakan adalah 80:20, artinya 80 persen data digunakan untuk pelatihan dan 20 persen untuk pengujian. Data pengujian harus benar-benar dipisahkan dan tidak digunakan sama sekali selama proses pelatihan model agar hasil evaluasi tetap objektif. Pemisahan ini penting untuk mencegah terjadinya *data leakage*, yaitu kondisi di mana informasi dari data uji secara tidak langsung mempengaruhi proses pelatihan sehingga dapat menghasilkan evaluasi yang bias dan tidak mencerminkan performa model yang sebenarnya. [14].

## 2.4 Model ML

Pada tahap pemodelan, setiap algoritma dilatih untuk mengenali pola hubungan antara fitur dan kelas target. Proses pemodelan ini juga dilengkapi dengan evaluasi menggunakan *cross-validation* guna memastikan bahwa Model tidak mengalami *overfitting* dan mampu beradaptasi dengan baik pada berbagai data baru. Proses pengklasifikasian dilakukan dengan menerapkan tiga jenis algoritma pembelajaran mesin, yaitu:

### 2.4.1 K-Nearest Neighbor (KNN)

Algoritma *K-Nearest Neighbor* (KNN) adalah salah satu algoritma yang banyak digunakan dalam pembelajaran mesin. Algoritma ini sering digunakan dalam berbagai bidang seperti pengenalan pola, klasifikasi, regresi, dan rekomendasi. *K-Nearest Neighbor* (KNN) bekerja dengan pendekatan *supervised*, dimana data baru akan diklasifikasikan berdasarkan mayoritas kategori yang dimiliki oleh K tetangga terdekat [15]. KNN melakukan klasifikasi pada suatu data berdasarkan nilai k yang telah ditetapkan sebelumnya. Nilai k pada KNN harus menggunakan nilai ganjil jika digunakan untuk proses klasifikasi, beda halnya jika digunakan untuk melakukan prediksi nilai k pada KNN dapat berupa bilangan ganjil ataupun genap [16]. Algoritma KNN menggunakan basis *Euclidean Distance* untuk menghitung jarak antar data sebagai berikut:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Di mana  $d(x, y)$  adalah jarak antara titik data  $x$  dan  $y$ ,  $x_i$  dan  $y_i$  adalah nilai fitur ke- $i$  dari masing-masing titik. Langkah-langkah pengerjaan KNN meliputi: (1) menentukan nilai K sebagai jumlah tetangga terdekat; (2) menghitung jarak antara data uji dengan seluruh data latih menggunakan persamaan *Euclidean Distance*; (3) mengurutkan jarak dari yang terkecil ke terbesar; (4) memilih K data dengan jarak terkecil sebagai tetangga terdekat; dan (5) menentukan kelas prediksi berdasarkan mayoritas kelas dari K tetangga tersebut.

### 2.4.2 Support Vector Learning (SVM)

*Support Vector Machine* (SVM) adalah pembelajaran ini menggunakan model berupa fungsi linear pada fitur dengan dimensi tinggi, yang dilatih menggunakan algoritma pembelajaran berbasis teori optimasi sehingga mampu menghasilkan model yang optimal [17][18]. Dalam konteks klasifikasi, *Support Vector Machine* (SVM) bertujuan untuk menemukan batas pemisah terbaik, yang dapat berupa garis atau bidang, untuk memisahkan data dengan margin maksimum. Proses ini dilakukan dengan memilih batas pemisah sedemikian rupa sehingga jarak antara batas tersebut dan data dari masing-masing kelas (yang disebut sebagai *support vectors*) menjadi maksimum [19]. Fungsi keputusan SVM didefinisikan sebagai berikut:

$$f(x) = \text{sign}(w \cdot x + b) \quad (2)$$

Di mana  $w$  adalah vektor bobot (*weight vector*),  $x$  adalah vektor fitur input, dan  $b$  adalah nilai *bias*. Optimasi margin maksimum dilakukan dengan meminimalkan  $\|w\|^2/2$ . Langkah-langkah pengerjaan SVM meliputi: (1) menyiapkan data latih dengan label kelas; (2) memilih fungsi *kernel* yang sesuai (linear, RBF, atau polynomial); (3) melatih model untuk menemukan *hyperplane* optimal dengan margin terbesar; (4) mengidentifikasi *support vectors* dari data latih; dan (5) mengklasifikasikan data uji berdasarkan posisinya terhadap *hyperplane*.

### 2.4.3 Random Forest (RF)

*Random Forest* adalah algoritma klasifikasi ensemble yang menggunakan pohon keputusan acak untuk menghasilkan prediksi yang lebih akurat dan stabil. Kelebihan dari *Random Forest* adalah memiliki akurasi yang tinggi, Stabilitas tinggi, mudah diinterpretasikan, dapat menangani data multi dimensi. Klasifikasi ini juga memiliki kekurangan yaitu, kompleksitas komputasi, *overfitting*, serta membutuhkan banyak data. Penerapan *Random Forest* dalam sebuah aplikasi dapat berupa klasifikasi teks, gambar, data medis, dan data keuangan [20]. *Random Forest* terdiri dari sekumpulan *decision tree*, dimana kumpulan pohon keputusan ini digunakan untuk mengklasifikasi data ke suatu kelas. Pohon keputusan dibuat dengan menentukan node akar dan berakhir dengan beberapa node daun untuk mendapatkan hasil akhir [21]. Prediksi akhir pada *Random Forest* ditentukan melalui agregasi hasil votasi mayoritas dari seluruh pohon keputusan yang dibangun, dengan rumus sebagai berikut:

$$H(x) = \text{mode}\{h_1(x), h_2(x), \dots, h_n(x)\} \quad (3)$$

Di mana  $H(x)$  adalah prediksi akhir,  $h_1(x)$  hingga  $h_n(x)$  adalah prediksi dari masing-masing pohon keputusan ke- $i$  dari total  $n$  pohon. Langkah-langkah pengerjaan *Random Forest* meliputi: (1) menentukan jumlah pohon keputusan ( $n_{\text{estimators}}$ ) dan parameter lainnya; (2) membangun setiap pohon menggunakan teknik *bootstrap sampling* dari data latih; (3) pada setiap node pohon, memilih sejumlah fitur secara acak sebagai kandidat pemisah; (4) memilih fitur terbaik berdasarkan kriteria *Gini Impurity* atau *Information Gain*; (5) mengulangi proses hingga semua pohon terbentuk; dan (6) menggabungkan prediksi seluruh pohon melalui mayoritas votasi untuk menghasilkan keputusan akhir.

## 2.5 Hyperparameter Tuning

Pada tahap *hyperparameter tuning*, proses optimasi dilakukan menggunakan *K-Fold cross validation* dengan variasi nilai  $k$  yaitu 5, 10, 15, dan 20. Sebagai bagian dari upaya peningkatan kinerja model, dilakukan *hyperparameter tuning* menggunakan pendekatan *grid search cross-validation*. Metode *GridSearchCV* yang terdiri dari ' $n_{\text{estimators}}$ ': [100, 200], ' $\text{max\_depth}$ ': [None, 8, 12] ' $\text{min\_samples\_split}$ ': [2, 5], ' $\text{min\_samples\_leaf}$ ': [1, 2], digunakan untuk secara sistematis mengevaluasi berbagai kombinasi parameter guna menemukan konfigurasi yang memberikan performa terbaik [22]. *Hyperparameter* yang tidak optimal dapat menyebabkan model mengalami *overfitting* atau *underfitting*, yang pada akhirnya berdampak pada penurunan kemampuan generalisasi model terhadap data baru [23].

## 2.6 Prediksi Data

Pada tahap prediksi, model klasifikasi terbaik yang telah diperoleh dari proses pelatihan dan optimasi *hyperparameter* menggunakan *K-Fold cross-validation* ( $k = 5, 10, 15, \text{ dan } 20$ ) diterapkan pada data uji untuk menghasilkan output berupa label prediksi maupun probabilitas kelas. Proses ini bertujuan mengukur seberapa baik model bisa menebak pola dari data yang belum pernah dilihat sebelumnya. Prediksi yang dihasilkan kemudian dibandingkan dengan nilai sebenarnya dari data uji untuk mengetahui sejauh mana kinerja model, dengan menggunakan beberapa ukuran seperti akurasi, presisi, *recall*, *F1-score*, dan nilai AUC.

## 2.7 Evaluasi Data

*Confusion matrix* digunakan untuk merepresentasikan jumlah prediksi benar dan salah dari model pada masing-masing kelas. Matriks ini terdiri atas empat komponen utama: *True Positif* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN) [24]. Pada penelitian ini, kinerja model *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), dan *Random Forest* dianalisis berdasarkan hasil prediksi pada data uji.

Evaluasi dilakukan dengan menghitung beberapa metrik kinerja model, yaitu akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*, serta *Area Under the Curve* (AUC), untuk mengukur kemampuan model dalam mengklasifikasikan data secara tepat. Adapun rumus yang digunakan untuk menghitung metrik evaluasi berdasarkan *confusion matrix* adalah sebagai berikut:

- a. *Accuracy*, merupakan ukuran yang menunjukkan perbandingan antara jumlah prediksi yang benar, baik pada kelas positif maupun negatif, terhadap total keseluruhan data. Secara matematis, *accuracy* dirumuskan sebagai berikut:

$$Accuracy = \frac{\text{jumlah prediksi benar}}{\text{jumlah total data}} \quad (4)$$

- b. *Precision*, merupakan ukuran ketepatan model dalam mengklasifikasikan data sebagai positif yang dihitung berdasarkan perbandingan antara jumlah *True Positive* terhadap seluruh data yang diprediksi positif. Rumus *precision* adalah sebagai berikut:

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

- c. *Recall*, menunjukkan kemampuan model dalam mengidentifikasi seluruh data positif yang sebenarnya, yaitu dengan membandingkan jumlah *True Positive* terhadap total data positif. Secara matematis, *recall* dirumuskan sebagai berikut:

$$Recall = \frac{TP}{TP+FN} \quad (6)$$

- d. *F1-Score*, merupakan rata-rata antara *precision* dan *recall* yang digunakan untuk menyeimbangkan performa model, terutama pada kondisi distribusi data yang tidak seimbang. Rumus *F1-Score* adalah sebagai berikut:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

Selain metrik evaluasi sederhana, kinerja model klasifikasi juga dapat dianalisis menggunakan *Receiver Operating Characteristic* (ROC) dan *Area Under the Curve* (AUC). Kurva ROC digunakan untuk menggambarkan perubahan performa model pada berbagai nilai batas keputusan (*threshold*) klasifikasi. Pada kurva ini, sumbu vertikal merepresentasikan *True Positive Rate* (TPR), sedangkan sumbu horizontal menunjukkan *False Positive Rate* (FPR).

- e. TPR atau *recall* menunjukkan tingkat keberhasilan model dalam mengenali data positif, yang dirumuskan sebagai berikut:

$$TPR = TP / (TP + FN) \quad (8)$$

- f. FPR menunjukkan persentase data negatif yang salah diprediksi sebagai positif, dengan rumus sebagai berikut:

$$FPR = \frac{FP}{TN+FP} \quad (9)$$

Nilai AUC merepresentasikan luas area yang berada di bawah kurva ROC. Nilai ini berada pada rentang 0 hingga 1, di mana semakin mendekati 1 menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara kelas positif dan kelas negatif, tanpa bergantung pada batas keputusan yang digunakan. Nilai AUC dapat diinterpretasikan sebagai berikut: nilai 0,5 menunjukkan model tidak memiliki kemampuan diskriminasi, nilai 0,7–0,8 tergolong cukup baik, 0,8–0,9 baik, dan di atas 0,9 sangat baik. Selain itu, kurva ROC juga memberikan gambaran mengenai *trade-off* antara tingkat deteksi positif dan tingkat kesalahan klasifikasi.

Keterangan:

TP (*True Positive*): Jumlah data positif (Sakit) yang diprediksi benar sebagai positif.

TN (*True Negative*): Jumlah data negatif (Normal) yang diprediksi benar sebagai negatif.

FP (*False Positive*): Jumlah data negatif yang salah diprediksi sebagai positif.

FN (*False Negative*): Jumlah data positif yang salah diprediksi sebagai negatif.

### 3. HASIL DAN PEMBAHASAN

Bab ini menyajikan pemaparan komprehensif mengenai hasil eksperimen klasifikasi menggunakan tiga algoritma pembelajaran mesin utama, yaitu *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), dan *Random Forest* (RF). Analisis dilakukan tidak hanya berdasarkan metrik standar seperti akurasi, tetapi juga melalui pengamatan mendalam terhadap stabilitas model pada berbagai *K-Fold cross validation* dan distribusi kesalahan klasifikasi melalui *Confusion Matrix*.

#### 3.1 Hasil Evaluasi Model

Evaluasi model dimulai dengan menguji stabilitas performa menggunakan teknik *Stratified K-Fold Cross Validation* dengan variasi nilai K sebesar 5, 10, 15, dan 20. Penggunaan variasi nilai K bertujuan untuk memastikan bahwa model yang dihasilkan tidak hanya unggul secara kebetulan pada satu distribusi data tertentu, melainkan memiliki kemampuan generalisasi yang kuat. Pada Tabel 2 dan 3 terlihat tren performa yang sangat menarik dari ketiga model tersebut.

**Tabel 2.** Perbandingan akurasi setiap K-Fold

K-Fold	Random Forest	SVM	KNN
K=5	0,927281	0,853283	0,832044
K=10	0,929243	0,855881	0,838515
K=15	0,931790	0,857176	0,836582
K=20	0,931152	0,857209	0,837221

**Tabel 3.** Perbandingan ROC-AUC setiap K-Fold


K-Fold	Random Forest	SVM	KNN
K=5	0,969615	0,917425	0,912875
K=10	0,969793	0,916772	0,915569
K=15	0,972346	0,916490	0,915041
K=20	0,971847	0,918410	0,916549

Model *Random Forest* yang ditunjukkan pada tabel 2 dan 3 menunjukkan dominasi yang tak tergoyahkan sejak pengujian awal pada K-Fold = 5, dimana model ini meraih tingkat akurasi sebesar 0,93, dan ROC-AUC 0,97, sehingga menjadikannya yang teratas jika dibandingkan dengan KNN dan SVM. Hasil ini juga tetap terjaga di K-Fold = 10, di mana *Random Forest* mencatatkan akurasi 0,93, serta ROC-AUC dengan nilai 0,97. Kinerja yang konsisten ini menunjukkan bahwa *Random Forest* dapat mempertahankan kualitas performa meskipun jumlah lipatan untuk validasi ditingkatkan. Kemudian pada K-Fold = 15, *Random Forest* menunjukkan hasil terbaik dengan akurasi 0,93, dan ROC-AUC dengan nilai 0,97, yang merupakan nilai ROC-AUC tertinggi dari semua konfigurasi. Sedangkan untuk K-Fold = 20, model ini juga terus menunjukkan keunggulannya dengan akurasi 0,93, serta ROC-AUC 0,97. Tingginya konsistensi nilai pada K-Fold yang lebih besar menunjukkan bahwa model ini memiliki kemampuan generalisasi yang sangat baik terhadap data. Secara umum, berdasarkan hasil analisis menyeluruh pada seluruh nilai K-Fold, dapat disimpulkan bahwa *Random Forest* merupakan model paling optimal dengan tingkat presisi yang tinggi. Di sisi lain, model SVM menunjukkan performa pada level menengah yang cenderung statis, sementara model KNN memberikan indikasi performa yang paling rendah di antara ketiganya, meskipun hasilnya masih berada dalam rentang yang dapat diterima (*acceptable range*) untuk klasifikasi. Perbedaan gap pada grafik menunjukkan jarak yang cukup signifikan antara *Random Forest* dengan dua algoritma lainnya, yang mempertegas keunggulan arsitektur *ensemble learning* dalam menangani kompleksitas fitur pada penelitian ini. Berikut gambar Perbandingan akurasi dan ROC-AUC terbaik dari ketiga metode tersebut.

Keunggulan stabilitas yang ditunjukkan oleh *Random Forest* di berbagai tingkatan K-Fold mencerminkan ketangguhan algoritma ini dalam memproses keberagaman distribusi data tanpa terjebak pada masalah *overfitting* maupun *underfitting*. Dengan nilai akurasi dan ROC-AUC yang tetap konstan meskipun jumlah lipatan validasi ditingkatkan, model ini terbukti memiliki varians yang rendah dan bias yang terkontrol secara optimal. Fenomena ini memberikan keyakinan teknis bahwa performa tinggi yang dihasilkan bukanlah sebuah kebetulan, melainkan hasil dari kemampuan arsitektur *decision trees* yang digabungkan secara ensemble dalam menangkap pola nonlinear pada fitur medis secara presisi. Oleh karena itu, konsistensi ini menjadi landasan kuat untuk menetapkan *Random Forest* sebagai solusi teknologi yang paling andal dalam mendukung efektivitas deteksi dini penyakit jantung di masa depan.

Gambar 2 menampilkan Akurasi dan ROC-AUC terbaik pada K-Fold 15. *Random Forest* meraih nilai akurasi paling tinggi mencapai 0,94, jauh dibandingkan SVM yang berkisar pada 0,86 dan KNN sekitar 0,83. Lalu, untuk akurasi terbaik dari ketiga metode tersebut, yaitu *Random Forest* dengan nilai akurasi mencapai 0,93, sedangkan untuk SVM di angka 0,86, dan KNN di posisi paling akhir dengan nilai akurasi 0,84. Ini menunjukkan bahwa *Random Forest* mampu mengklasifikasikan data dengan hasil yang lebih tepat. Di samping itu, untuk ROC-AUC juga dipakai untuk mengetahui

sejauh mana model bisa membedakan tingkat kemungkinan antar kelas secara lebih dalam, terutama pada model yang memproduksi nilai *diagnostic* seperti *Random Forest* dan SVM.



**Gambar 2.** Akurasi dan ROC-AUC terbaik pada K-Fold 15. (Kiri) perbandingan akurasi pada tiga model. (Kanan) perbandingan AUC-ROC pada tiga model.

Selain unggul dalam akurasi, *Random Forest* juga menunjukkan dominasi pada metrik ROC-AUC dengan skor yang melampaui 0,97. Hal ini mengindikasikan bahwa model tersebut memiliki kemampuan yang sangat baik dalam membedakan antara kelas positif dan negatif dibandingkan SVM dan KNN yang skornya cenderung tertahan di kisaran 0,91. Penggunaan metode 15-Fold Cross Validation memberikan validasi yang lebih kuat terhadap hasil ini. Selisih performa yang cukup signifikan antara *Random Forest* dengan kedua algoritma lainnya menunjukkan bahwa arsitektur berbasis *ensemble learning* pada *Random Forest* lebih efektif dalam menangani kompleksitas dataset ini.

Dengan demikian, berdasarkan kedua parameter evaluasi tersebut (Akurasi dan ROC-AUC), model *Random Forest* ditetapkan sebagai model yang paling optimal untuk digunakan dalam klasifikasi ini karena memberikan tingkat kepercayaan (*confidence level*) yang paling tinggi

Setelah mengamati stabilitas melalui berbagai nilai K, konfigurasi 15-Fold dipilih sebagai parameter terbaik untuk membandingkan performa puncak antar model. Ringkasan perbandingan metrik evaluasi ini disajikan pada Tabel 4.

**Tabel 4.** Hasil evaluasi semua model.

Metrik	RF	SVM	KNN
Accuracy	0,931790	0,857176	0,836582
Precision	0,924172	0,863367	0,863812
Recall	0,950411	0,870628	0,825758
F1-Score	0,936787	0,866347	0,842477
ROC-AUC	0,972346	0,916490	0,915041

Tabel 4 menunjukkan detail hasil evaluasi berdasarkan penilaian yang telah dilakukan dengan menggunakan metode 15-Fold diperoleh hasil model *Random Forest* mencapai akurasi puncak sebesar 0,931, jauh melampaui SVM (0,857) dan KNN (0,836). Selisih akurasi sekitar 7-9% ini merupakan angka yang signifikan dalam dunia medis, karena setiap persentase merepresentasikan ketepatan diagnosa terhadap sejumlah pasien. Hal ini bisa dilihat Tabel 2 dan 3 menunjukkan bahwa seluruh parameter evaluasi. *Random Forest* mencatatkan nilai *precision* sebesar 0,924; *recall* 0,950; dan *F1-score* 0,936. Dalam deteksi penyakit jantung, metrik *recall* adalah yang paling krusial karena mengukur kemampuan model dalam mengidentifikasi seluruh pasien yang benar-benar sakit (meminimalisir *False Negative*). *Random Forest* mencatatkan *Recall* tertinggi sebesar 0,950. Artinya, dari 100 orang yang benar-benar sakit, RF mampu mendeteksi 95 di antaranya dengan benar, sementara SVM dan KNN memiliki risiko kegagalan deteksi yang lebih tinggi. Sebagai perbandingan, SVM mencatatkan akurasi sebesar 0,857, sementara KNN berada pada level terendah dengan akurasi 0,836. Tingginya nilai *recall* pada RF (0,950) menjadi poin krusial dalam penelitian medis ini, karena menunjukkan kemampuan model yang sangat tinggi dalam mendeteksi pasien yang benar-benar sakit. Hasil evaluasi pada data uji di penelitian ini menunjukkan nilai akurasi yang lebih tinggi dibandingkan penelitian-penelitian yang telah dilakukan sebelumnya [10],[8],[5].

Analisis pada Tabel 5 menunjukkan bahwa metode yang diusulkan dalam penelitian ini memberikan kinerja paling unggul dibandingkan dengan pendekatan pada penelitian terdahulu. Kombinasi *Random Forest* dengan *Stratified K-Fold Cross Validation* mampu mencapai akurasi sebesar 93,17%, yang merupakan nilai tertinggi di antara seluruh metode yang dibandingkan. Dibandingkan dengan penelitian yang dilakukan oleh Edric dkk [10], yang menggunakan *Random Forest* dengan *GridSearchCV* dan memperoleh akurasi 84,06%, serta penelitian yang dilakukan oleh Wheisky dkk [8], dengan metode SVM sebesar 84,81% dan Ryfai dkk [5], dengan metode KNN sebesar 88,33%, metode yang diusulkan menunjukkan peningkatan performa yang signifikan. Hal ini mengindikasikan bahwa strategi validasi yang digunakan mampu mengoptimalkan proses pelatihan model secara lebih efektif.

**Tabel 5.** Perbandingan akurasi.


Metode	Akurasi	Peneliti (Tahun)
<i>Random Forest</i> + <i>GridSearchCV</i>	84,06%	Edric, Saut Parsaoran Tamba (2022)

SVM	84,81%	Wheisky Steven Dharmawan (2021)
KNN	88,33%	Ryfai dan Santoso (2022)
<i>Random Forest+Stratified K-Fold Cross Validation</i>	93,17%	Metode yang diusulkan dalam penelitian ini (2026)

Skor ROC-AUC pada penelitian ini sebesar 0,972 pada *Random Forest* menunjukkan kemampuan pemisahan kelas yang hampir sempurna. Visualisasi pada Gambar 2 memperlihatkan gap yang lebar antara *Random Forest* dan dua model lainnya, yang membuktikan bahwa model probabilistik *Random Forest* sangat andal dalam membedakan antara pasien sehat dan berisiko. Secara keseluruhan, hasil penelitian ini menegaskan bahwa kombinasi algoritma *Random Forest* dengan teknik validasi yang tepat mampu menghasilkan model klasifikasi yang akurat, stabil, dan andal. Pendekatan ini memiliki potensi yang kuat untuk diterapkan dalam pengembangan sistem prediksi, khususnya pada konteks deteksi penyakit, karena mampu memberikan hasil yang konsisten serta mendukung pengambilan keputusan secara lebih tepat.

### 3.2 Confusion Matrix

Gambar 3 menampilkan nilai *confusion matrix* dari model *Random Forest*, *K-Nearest Neighbor* (KNN), dan *Support Vector Machine* (SVM) yang diterapkan dalam studi ini untuk mendeteksi kemungkinan terjadinya penyakit jantung. Setiap *confusion matrix* memperlihatkan jumlah prediksi yang akurat dan yang keliru berdasarkan dua kelas target, yaitu tidak berisiko penyakit jantung (kelas 0) dan berisiko penyakit jantung (kelas 1).



**Gambar 3.** Confusion Matrix KNN, RF, SVM

*Confusion Matrix* yang ditunjukkan pada gambar 3, model KNN menunjukkan kinerja yang kurang optimal jika dibandingkan dengan *Random Forest*, di mana model ini hanya mampu menghasilkan 163 prediksi akurat untuk kategori 0 dan 175 prediksi akurat untuk kategori 1. Di sisi lain, tingkat kesalahan pada model ini cukup signifikan, dengan rincian 19 kasus *False Positive* dan 32 kasus *False Negative*. Banyaknya jumlah *False Negative* pada KNN mengindikasikan bahwa model ini memiliki kelemahan dalam mendeteksi individu yang sebenarnya sakit, yang mana hal ini sangat berisiko dalam skenario diagnosis medis. Kesenjangan antara jumlah prediksi benar dan kesalahan klasifikasi menunjukkan bahwa algoritma berbasis jarak ini kesulitan dalam memisahkan batas kelas pada dataset yang digunakan.

Pada *Confusion Matrix* model *Random Forest*, tampak bahwa model tersebut dapat mengkategorikan data dengan tingkat akurasi yang tinggi, dengan jumlah 173 prediksi yang tepat untuk kelas 0 dan 196 prediksi tepat untuk kelas 1. Model ini berhasil menekan margin kesalahan secara signifikan hingga hanya tersisa 9 prediksi salah pada *False Positive* dan 11 prediksi pada *False Negative*. Rendahnya jumlah *False Negative* menunjukkan bahwa *Random Forest* memiliki sensitivitas yang sangat baik dalam mengenali gejala penyakit jantung. Keberhasilan model dalam meminimalisir kedua jenis kesalahan tersebut membuktikan bahwa pendekatan *ensemble learning* mampu menangani kompleksitas fitur data dengan lebih seimbang dibandingkan model lainnya.

Pada *Confusion Matrix* model SVM, terdapat 155 prediksi akurat untuk kategori 0 dan 186 prediksi akurat untuk kategori 1, dengan total kesalahan prediksi mencapai 27 *False Positive* dan 21 *False Negative*. Meskipun SVM menunjukkan performa yang lebih baik daripada KNN dalam hal identifikasi kelas positif (rendahnya *False Negative*), namun model ini masih memiliki angka *False Positive* yang paling tinggi di antara ketiga model. (berisiko terhadap penyakit jantung), meskipun masih tidak sebaik performa yang ditunjukkan oleh model *Random Forest*.

Dengan demikian, melalui observasi mendalam terhadap *Confusion Matrix* di atas, dapat disimpulkan bahwa *Random Forest* merupakan algoritma yang paling reliabel untuk digunakan dalam sistem deteksi dini ini. Kemampuannya dalam menjaga keseimbangan antara presisi dan *recall* menjadikannya pilihan model yang paling optimal dari sisi teknis maupun aplikatif.

### 3.3 Pemilihan Model Terbaik

Berdasarkan hasil pengujian dan evaluasi mendalam terhadap ketiga algoritma yang digunakan, yaitu *Random Forest* (RF), *Support Vector Machine* (SVM), dan *K-Nearest Neighbor* (KNN), maka ditetapkan bahwa *Random Forest* merupakan model terbaik dalam penelitian ini. Keunggulan metrik akurasi dan ROC-AUC pada model *Random Forest* menunjukkan performa paling dominan dengan nilai akurasi mencapai 0,93, yang secara signifikan lebih tinggi dibandingkan dengan SVM sebesar 0,86 dan KNN sebesar 0,84. Dibandingkan penelitian sebelumnya yang dilakukan

oleh Edric dkk. [10], penelitian menggunakan *Random Forest* yang dilakukan hanya mencapai akurasi 0,84. Selain itu, nilai ROC-AUC *Random Forest* pada penelitian ini menyentuh angka 0,97 mengonfirmasi kemampuan model yang sangat baik dalam membedakan antar-kelas dibandingkan kedua model lainnya yang berada di kisaran 0,91.

Secara medis, rendahnya jumlah *False Negative* pada model *Random Forest* (11 kasus) dibandingkan dengan KNN (32 kasus) dan SVM (21 kasus) menjadi poin krusial. Hal ini menunjukkan bahwa *Random Forest* memiliki sensitivitas yang lebih tinggi dalam mendeteksi individu yang berisiko terkena penyakit jantung, sehingga meminimalisir kegagalan diagnosa yang berpotensi fatal. Dominasi warna biru gelap yang lebih terkonsentrasi pada diagonal utama (*True Positive* dan *True Negative*) di matriks *Random Forest* mengonfirmasi bahwa model ini memiliki stabilitas prediksi yang lebih konsisten dibandingkan dua algoritma lainnya. Kesalahan prediksi yang relatif kecil pada kedua kelas menunjukkan bahwa model tidak cenderung bias terhadap salah satu kategori.

Penggunaan metode 15-Fold *cross-validation* memberikan validasi yang kuat bahwa keunggulan *Random Forest* bersifat stabil dan tidak hanya terjadi secara acak pada satu distribusi data tertentu. Secara keseluruhan, integrasi antara nilai akurasi yang tinggi serta rendahnya margin kesalahan pada *Confusion Matrix* menjadikan *Random Forest* sebagai model paling optimal dan reliabel untuk diimplementasikan dalam sistem klasifikasi pada penelitian ini.

Pencapaian performa yang sangat tinggi pada model *Random Forest* ini membuktikan bahwa algoritma berbasis *ensemble learning* jauh lebih adaptif dalam menangani korelasi fitur yang kompleks pada dataset penyakit jantung dibandingkan algoritma berbasis jarak seperti KNN atau pemisahan linear pada SVM. Keberhasilan model dalam mempertahankan nilai akurasi 0,93 dan ROC-AUC 0,97 secara konsisten di berbagai pengujian K-Fold memberikan jaminan bahwa sistem ini memiliki kemampuan generalisasi yang baik untuk diimplementasikan pada data baru yang belum pernah dilihat sebelumnya (*unseen data*). Meskipun penelitian ini menunjukkan hasil yang baik, terdapat beberapa keterbatasan, antara lain jumlah dataset yang masih terbatas dan belum mencakup variasi populasi yang lebih luas. Selain itu, penelitian ini belum mengeksplorasi metode optimasi lanjutan atau algoritma *deep learning* yang berpotensi meningkatkan performa model. Penelitian selanjutnya dapat mengembangkan model dengan menambahkan teknik *feature selection*, menggunakan dataset yang lebih besar, serta menguji algoritma lain seperti *deep learning* untuk meningkatkan akurasi dan generalisasi model. Dengan demikian, integrasi antara optimasi *hyperparameter* dan teknik *Stratified K-Fold* yang diterapkan dalam penelitian ini tidak hanya meningkatkan presisi secara numerik, tetapi juga memberikan solusi teknologi yang lebih aman dan andal bagi para praktisi medis dalam melakukan deteksi dini risiko penyakit jantung.

## 4. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan kinerja algoritma *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), dan *Random Forest* (RF) dalam klasifikasi penyakit jantung dengan menerapkan teknik *Stratified K-Fold Cross Validation*. Berdasarkan hasil pengujian yang telah dilakukan, diperoleh hasil bahwa *Random Forest* merupakan algoritma dengan performa terbaik. Hal ini ditunjukkan melalui nilai evaluasi metrik *accuracy*, *precision*, *recall*, *F1-score*, dan ROC-AUC, serta kemampuannya dalam meminimalkan kesalahan klasifikasi, terutama pada *False Negative* yang memiliki peran penting dalam konteks diagnosis medis karena berkaitan langsung dengan risiko keterlambatan penanganan pasien. Penerapan *Stratified K-Fold Cross Validation* terbukti mampu meningkatkan stabilitas model dan kemampuan generalisasi terhadap data baru, karena distribusi data pada setiap fold tetap terjaga secara seimbang. Secara keseluruhan, penelitian ini menunjukkan bahwa kombinasi algoritma *Random Forest* dan teknik *Stratified K-Fold Cross Validation* yang optimal mampu menghasilkan model klasifikasi yang akurat, stabil, dan andal dalam mendeteksi penyakit jantung. Hasil penelitian ini berpotensi untuk diimplementasikan dalam sistem pendukung keputusan medis guna membantu tenaga kesehatan dalam melakukan deteksi dini, meningkatkan efisiensi diagnosis, serta mendukung pengambilan keputusan yang lebih cepat, tepat, dan berbasis data.

## REFERENCES

- [1] D. Pradana, M. Luthfi Alghifari, M. Farhan Juna, and D. Palaguna, "Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network," *Indones. J. Data Sci.*, vol. 3, no. 2, pp. 55–60, 2022, doi: 10.56705/ijodas.v3i2.35.
- [2] U. Athiyah *et al.*, "Diagnosa Resiko Penyakit Jantung Menggunakan Logika Fuzzy Metode Tsukamoto," *Infokes*, vol. 11, no. 1, pp. 31–40, 2021.
- [3] B. Hirwono, A. Hermawan, and D. Avianto, "Implementasi Metode Naïve Bayes untuk Klasifikasi Penderita Penyakit Jantung," *J. JTIK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 7, no. 3, pp. 450–457, 2023, doi: 10.35870/jtik.v7i3.910.
- [4] W. K. Sari and I. S. B. Azhar, "Perbandingan Kinerja Neural Network dengan Metode Klasifikasi Tradisional dalam Mendiagnosis Penyakit Jantung: Sebuah Studi Komparatif," *JSI J. Sist. Inf.*, vol. 15, no. 1, pp. 3111–3117, 2023, doi: 10.18495/jsi.v15i1.112.
- [5] M. Praditapuspa, Gala Sifa; Annisa, Rahmadani; Safari, "Uji aktivitas analgesik fraksi etil asetat daun kersen (*Muntingia calabura L.*) dengan metode hot plate," *J. Ilmu Farm. dan Farm. Klin.*, vol. 6, no. 10, pp. 4701–4707, 2020, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/11662>
- [6] F. Yulian Pamuji, Ahmad Rofiqul Muslikh, Rizza Muhammad Arief, and Delviana Muti, "Komparasi Metode Mean dan KNN Imputation dalam Mengatasi Missing Value pada Dataset Kecil," *J. Inform. Polinema*, vol. 10, no. 2, pp. 257–264, 2024, doi: 10.33795/jip.v10i2.5031.
- [7] W. Nursahid, B. I. Nugroho, and S. Syefudin, "Optimalisasi Preprocessing Data Menggunakan Pendekatan CRISP-DM untuk

- Meningkatkan Kualitas Klasifikasi Penyakit Jantung,” *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 3, pp. 3621–3626, 2025, doi: 10.31004/riggs.v4i3.2514.
- [8] W. S. Dharmawan, “Informatika Dalam Prediksi Penyakit Jantung,” *J. Inform. Manaj. dan Komput.*, vol. 13, no. 2, pp. 31–41, 2021.
- [9] A. Faradisya and M. A. I. Pakereng, “Analisis Komparatif Kernel Linear, Polynomial, RBF, dan Sigmoid pada Support Vector Machine untuk Klasifikasi Penyakit Jantung: Comparative Analysis of Linear, Polynomial, RBF, and Sigmoid Kernels in Support Vector Machine for Heart Disease Classification,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 4, pp. 1531–1537, 2025.
- [10] S. P. Tamba and E. -, “Prediksi Penyakit Gagal Jantung Dengan Menggunakan Random Forest,” *J. Sist. Inf. dan Ilmu Komput. Prima (USIKOM PRIMA)*, vol. 5, no. 2, pp. 176–181, 2022, doi: 10.34012/jurnalsisteminformasidanilmukomputer.v5i2.2445.
- [11] G. Rizky, *Dataset Jantung*. 2025. [Online]. Available: <https://www.kaggle.com/datasets/ginantiriski/dataset-jantung>
- [12] J. Zulkaidah, *Data Penyakit Jantung*. 2023. [Online]. Available: <https://www.kaggle.com/datasets/jumainzulkaidah/data-penyakit-jantung>
- [13] S. Khairunnisa, A. Adiwijaya, and S. Al Faraby, “Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19),” *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 406, 2021, doi: 10.30865/mib.v5i2.2835.
- [14] Putri Azhiah, Jasmir, and Purnama Benni, “Klasifikasi Kelayakan Penerima Beasiswa Menggunakan Naive Bayes dengan Optimasi Atribut Berbasis K-Means,” *Inst. Ris. dan Publ. Indones.*, vol. 5, no. October, pp. 1450–1462, 2025.
- [15] Sopiatal Ulum, R. F. Alifa, P. Rizkika, and C. Rozikin, “Perbandingan Performa Algoritma KNN dan SVM dalam Klasifikasi Kelayakan Air Minum,” *Gener. J.*, vol. 7, no. 2, pp. 141–146, 2023, doi: 10.29407/gj.v7i2.20270.
- [16] A. Khairi, A. F. Ghozali, and A. D. N. Hidayah, “Implementasi K-Nearest Neighbor (KNN) untuk Mengklasifikasi Masyarakat Pra-Sejahtera Desa Sapikerep Kecamatan Sukapura,” *TRILOGI J. Ilmu Teknol. Kesehatan, dan Hum.*, vol. 2, no. 3, pp. 319–323, 2021, doi: 10.33650/trilogi.v2i3.2878.
- [17] A. Rahman Isnain, A. Indra Sakti, D. Alita, and N. Satya Marga, “Sentimen Analisis Publik Terhadap Kebijakan Lockdown Pemerintah Jakarta menggunakan Algoritma Support Vector Machine (SVM),” *Jdmsi*, vol. 2, no. 1, pp. 31–37, 2021, [Online]. Available: <https://t.co/NfhmfMjtXw>
- [18] M Riski Qisthiano, “Klasifikasi Terhadap Prediksi Kelulusan Mahasiswa Dengan Menggunakan Metode Support Vector Machine (Svm),” *Semin. Nas. Teknol. dan Multidisiplin Ilmu*, vol. 2, no. 2, pp. 203–207, 2022, doi: 10.51903/semnastekmu.v2i1.170.
- [19] A. S. Prabowo and F. I. Kurniadi, “Analisis Perbandingan Kinerja Algoritma Klasifikasi dalam Mendeteksi Penyakit Jantung,” *J. SISKOM-KB (Sistem Komput. dan Kecerdasan Buatan)*, vol. 7, no. 1, pp. 56–61, 2023, doi: 10.47970/siskom-kb.v7i1.468.
- [20] M. N. Raza, “Sistem Deteksi Berita Hoax Menggunakan Algoritma Naïve Bayes Dan Random Forest Pada Machine Learning,” *Pondasi J. Appl. Sci. Eng.*, vol. 1, no. 2, pp. 43–57, 2024, [Online]. Available: <https://journal.alshobar.or.id/index.php/pondasi/article/view/221>
- [21] Suci Amaliah, M. Nusrang, and A. Aswi, “Penerapan Metode Random Forest Untuk Klasifikasi Varian Minuman Kopi di Kedai Kopi Konijiwa Bantaeng,” *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 4, no. 3, pp. 121–127, 2022, doi: 10.35580/variansium31.
- [22] C. Azzaria, E. Daniati, and A. Ristyawan, “Peningkatan Akurasi Deteksi Liver Disease melalui Hyperparameter Tuning pada Algoritma Random Forest,” *Indones. J. Comput. Sci. Res.*, vol. 4, no. 2, pp. 139–147, 2025, [Online]. Available: <https://subset.id/index.php/IJCSR>
- [23] A. Setiawan, A. A. Siregar, N. Setiawan, J. Nasution, and N. D. Putra, “Optimasi Performa Model SVM dan Random Forest untuk Klasifikasi Kanker Payudara Menggunakan Penyetelan Hyperparameter,” *J. Komput. Teknol. Inf. Sist. Komput.*, vol. 4, no. 3, pp. 2141–2149, 2026.
- [24] M. Anita, I. G. D. Yulianti, and S. V. Pasaribu, “Klasifikasi Faktor Risiko Penyakit Jantung Menggunakan Machine Learning,” *HOAQ (High Educ. Organ. Arch. Qual. J. Teknol. Inf.)*, vol. 16, no. 1, pp. 68–78, 2025, doi: 10.52972/hoaq.vol16no1.p68-78.