

PERBANDINGAN ALGORITMA RANDOM FOREST, NAIVE BAYES, DAN NEURAL NETWORK DALAM KLASIFIKASI PENYAKIT JANTUNG

Maulidina Cahaya Rani¹⁾, Farah Diba Azkia²⁾, Revinta Arrova Dewi³⁾, Mochamad Wahyudi⁴⁾, Sumanto⁵⁾, Ade Surya Budiman⁶⁾

^{1,2,3}Mahasiswa Program Studi Informatika, Universitas Bina Sarana Informatika

^{4,5,6}Dosen Program Studi Informatika, Universitas Bina Sarana Informatika

Corresponding Author: maulidinarani90@gmail.com

Article Info

Article history:

Received Mei 16, 2025

Revised Juni 16, 2025

Accepted Juni 26, 2025

Keywords:

Penyakit Jantung
Random Forest
Neural Network
Naïve Bayes

ABSTRACT

Penyakit jantung merupakan salah satu masalah kesehatan paling mematikan di dunia, dengan jumlah kematian yang terus meningkat setiap tahunnya. Penyakit kardiovaskular adalah penyebab utama kematian di seluruh dunia, dengan lebih dari 17 juta kematian setiap tahun, menurut data WHO. Gangguan fungsi jantung ini dapat dipicu oleh berbagai faktor risiko seperti pola makan tidak sehat, obesitas, kurang aktivitas fisik, kebiasaan merokok, dan riwayat penyakit dalam keluarga. Oleh karena itu, deteksi dini sangat penting untuk mencegah dan mengurangi risiko kematian akibat penyakit jantung. Penelitian ini bertujuan untuk membandingkan performa tiga metode klasifikasi, yaitu Random Forest, Neural Network, dan Naive Bayes dalam mengklasifikasi risiko penyakit jantung. Pengujian model dilakukan menggunakan metode Random Sampling dengan skema repeat train/test sebanyak 10 kali, di mana setiap iterasi menggunakan 80% data sebagai training set. Berdasarkan hasil evaluasi, model Random Forest menghasilkan nilai AUC sebesar 0,996, model Naive Bayes sebesar 0,980, dan model Neural Network sebesar 0,957. Selain itu, analisis dilakukan untuk menilai keunggulan dan kelemahan masing-masing metode dalam menangani data dengan fitur yang kompleks dan saling berkorelasi. Hasil penelitian ini diharapkan dapat memberikan rekomendasi metode klasifikasi yang paling efektif dan efisien untuk diterapkan dalam sistem pendukung keputusan medis guna deteksi dini penyakit jantung.



This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY NC SA 4.0) which permits unrestricted use, distribution, and reproduction in any medium for non-commercial use provided the original author and source are credited.

1. INTRODUCTION

Jantung berperan penting dalam memompa darah ke seluruh tubuh melalui pembuluh darah, sehingga sangat vital bagi kelangsungan hidup manusia. Namun, penyakit jantung dapat mengganggu fungsi organ ini dan berdampak serius terhadap kesehatan [1] [2]. Berbagai faktor risiko diketahui menjadi penyebab utama penyakit jantung, antara lain pola makan tidak sehat, kelebihan berat badan, kurangnya aktivitas fisik, kebiasaan merokok, serta adanya riwayat penyakit jantung dalam keluarga. Oleh karena itu, upaya deteksi dini sangat diperlukan untuk menurunkan risiko serta angka kematian akibat penyakit ini [3].

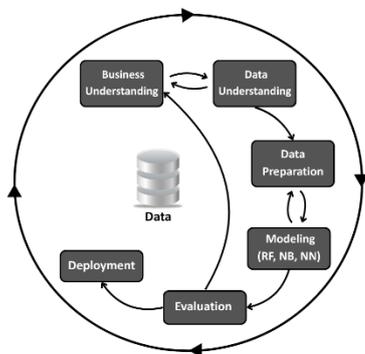
Penyakit *kardiovaskular* (*cardiovascular disease*) merupakan penyebab kematian terbanyak di seluruh dunia, meskipun tergolong penyakit tidak menular. Data dari World Health Organization (WHO) menunjukkan bahwa lebih dari 17 juta kematian terjadi setiap tahunnya akibat penyakit ini [4] [5]. Kondisi tersebut menunjukkan perlunya solusi berbasis teknologi untuk mendukung proses deteksi dini yang cepat, tepat, dan efisien.

Beberapa penelitian sebelumnya telah membahas klasifikasi penyakit jantung menggunakan berbagai algoritma *machine learning*, seperti *Random Forest*, *Artificial Neural Network* (ANN), *Support Vector Machine* (SVM), *Naive Bayes*, dan *Decision Tree* [6]. Tujuannya adalah untuk memprediksi apakah

seorang berisiko menderita penyakit jantung berdasarkan data klinis yang dimilikinya. Akurasi tertinggi yang dicapai dalam penelitian-penelitian tersebut berkisar di angka 90%, tergantung pada teknik yang digunakan, seperti *praproses data*, pengaturan *hiperparameter*, serta penyeimbangan data.

Penelitian ini dilakukan untuk membandingkan kinerja tiga algoritma klasifikasi, yaitu *Random Forest*, *Naive Bayes*, dan *Neural Network* dalam mendeteksi risiko penyakit jantung. Data yang digunakan berjumlah 1.320 entri pasien yang diperoleh dari situs Kaggle. Metode pengujian dilakukan dengan pendekatan *random sampling* dan skema pelatihan dan pengujian sebanyak sepuluh kali, dengan proporsi 80 persen data sebagai data latih pada setiap iterasi. Hasil penelitian ini diharapkan dapat memberikan gambaran tentang algoritma klasifikasi yang paling efektif dan efisien dalam proses deteksi dini penyakit jantung berdasarkan matrik evaluasi seperti akurasi, presisi, recall, dan F1-score, serta memberikan rekomendasi metode yang andal untuk diterapkan dalam sistem pendukung keputusan medis.

2. MATERIALS AND METHODS



Gambar 1. Tahapan Penelitian

Pada Gambar 1 merupakan gambaran penelitian ini dilakukan dengan mengikuti tahapan yang mengacu pada metode *CRISP-DM (Cross Industry Standard Process for Data Mining)* yang terdiri dari enam tahap utama, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Adapun penjelasan dari masing-masing tahapan tersebut dalam konteks penelitian ini adalah sebagai berikut:

2.1. Business Understanding

Tahapan ini bertujuan untuk memahami konteks masalah yang akan diselesaikan. Fokus utama penelitian adalah membandingkan performa tiga algoritma klasifikasi yaitu *Random Forest*, *Naive Bayes*, dan *Neural Network* dalam mengidentifikasi penyakit jantung. Penyakit jantung merupakan salah satu penyebab kematian tertinggi di dunia, sehingga deteksi dini sangat penting. Oleh karena itu, penelitian ini diarahkan untuk mencari algoritma yang paling

akurat dan efisien untuk membantu diagnosis awal secara otomatis.

2.2. Data Understanding

Dalam penelitian ini, digunakan *dataset* yang relevan untuk mendukung proses klasifikasi, yang meliputi data sampel, metode pengumpulan data, jenis data, sumber data, serta teknik analisis yang digunakan. *Dataset* yang digunakan adalah *Heart Disease Classification*, diperoleh dari situs Kaggle (<https://www.kaggle.com/>). *Dataset* ini terdiri dari 1.320 data observasi dengan sembilan atribut, yaitu: *age*, *gender*, *impluse*, *pressurehigh*, *pressurelow*, *glucose*, *kcm*, *troponin*, dan *class* [6]. Rincian 9 atribut tersebut disajikan pada Table 1.

Tabel 1. Atribut Dataset

Atribut	Keterangan	Tipe Data
Age	Usia pasien	Integer
Gender	Jenis kelamin pasien	Integer
Impluse	Detak jantung pasien	Integer
Pressurehigh	Jika pasien menderita hipertensi	Integer
Pressurelow	Jika pasien menderita tekanan darah rendah	Integer
Glucose	Kadar gula rendah	Float
KCM	Keratin Kinase- MB Level pasien	Float
Troponin	Jumlah protein pada otot jantung	Float
Class	Tabel atau diagnosa pasien	Object

2.3. Data Preparation

Preprocessing adalah proses mengubah data yang tidak terstruktur menjadi data yang terstruktur, yang dapat digunakan untuk analisis atau pemodelan berikutnya [7]. Untuk melakukan penelitian ini, Orange Data Mining adalah perangkat lunak yang digunakan. Proses dimulai dengan menggunakan fitur *import data* untuk memuat *dataset* ke dalam Orange. Selanjutnya, proses seleksi fitur juga dilakukan untuk memilih atribut yang paling relevan dengan tujuan klasifikasi, sehingga dapat meningkatkan efektivitas dan efisiensi model. Selain itu, data dibagi menjadi *subset* pelatihan dan pengujian melalui teknik *sampling* untuk mengevaluasi model yang optimal. Setelah proses *preprocessing* ini selesai, data yang digunakan siap untuk tahap pemodelan berikutnya.

2.4. Modeling (Implementasi Permodelan)

Pada tahap pemodelan, data yang telah melalui proses *preprocessing* digunakan untuk membangun

model klasifikasi penyakit jantung. Beberapa algoritma *machine learning* yang diterapkan antara lain *Random Forest*, *Naive Bayes*, dan *Neural Network*. Proses pemodelan dilakukan dengan membagi *dataset* menjadi data pelatihan dan data pengujian guna mengevaluasi performa model secara objektif. Setiap algoritma dilatih menggunakan data pelatihan dan diuji pada data pengujian untuk mengukur akurasi, presisi, recall, serta metrik evaluasi lainnya. Dengan metode ini, diharapkan dapat diperoleh model klasifikasi yang optimal dan dapat digunakan sebagai alat bantu dalam mengklasifikasikan penyakit jantung.

2.5. Evaluation (Evaluasi Model)

Evaluasi model dilakukan untuk mengukur performa algoritma klasifikasi yang telah dibangun dengan menggunakan data pengujian yang berbeda dari data pelatihan. Salah satu metode evaluasi yang digunakan adalah *confusion matrix*, yang menyajikan informasi jumlah prediksi benar dan salah pada setiap kelas untuk menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score [8]. Selain itu, analisis *Receiver Operating Characteristic (ROC)* dan perhitungan *Area Under the Curve (AUC)* digunakan untuk menilai kemampuan model dalam membedakan kelas positif dan negatif secara keseluruhan. Kurva *ROC* memberikan visualisasi *trade-off* antara sensitivitas dan spesifisitas pada berbagai nilai *threshold*, sementara nilai *AUC* merepresentasikan performa model secara kuantitatif. Kombinasi kedua pendekatan ini digunakan untuk membandingkan efektivitas algoritma *Random Forest*, *Naive Bayes*, dan *Neural Network* dalam klasifikasi penyakit jantung, serta menentukan model terbaik sebagai alat bantu diagnosis [6]

2.6. Deployment

Tahap terakhir dalam *CRISP-DM* adalah *deployment*. Dalam penelitian ini, *deployment* dilakukan dalam bentuk penyimpulan hasil evaluasi dan penyusunan dokumentasi penelitian. Hasil dari model terbaik dijadikan sebagai rekomendasi untuk pengembangan sistem pendukung keputusan medis, khususnya dalam hal diagnosis dini penyakit jantung. Selain itu, *workflow* Orange yang telah dibuat juga dapat disimpan sebagai *prototipe* untuk implementasi lanjutan.

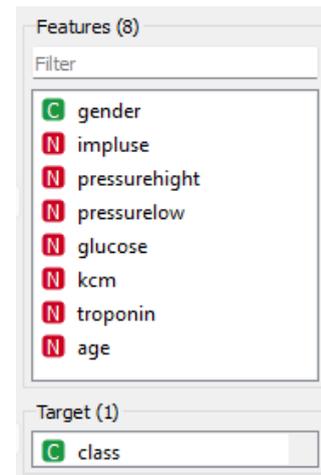
3. RESULTS AND DISCUSSION

Hasil dan pembahasan penelitian yang dilakukan adalah sebagai berikut.

3.1. Pemetaan Atribut

Pada penelitian ini, *dataset* yang digunakan telah dipastikan tidak mengandung nilai kosong (*missing value*), sehingga layak untuk dianalisis lebih lanjut. Tahapan *preprocessing* data mencakup seleksi atribut, di mana atribut "*class*" ditetapkan sebagai variabel target untuk mencari diagnosa pasien, sementara atribut lainnya difungsikan sebagai variabel fitur.

Rincian lengkap mengenai *dataset* yang digunakan disajikan pada Gambar 2.

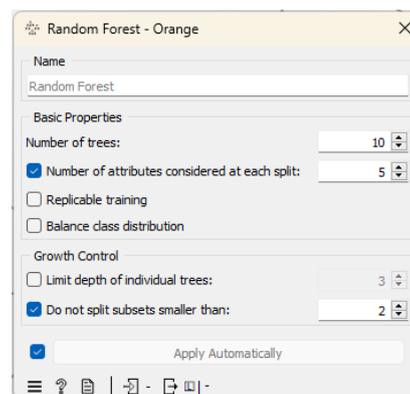


Gambar 2. Features dan Target

3.2. Implementasi Model

3.2.1. Random Forest

Random Forest merupakan algoritma *ensemble learning* yang terdiri dari sekumpulan *decision tree* yang dibentuk berdasarkan sampel data dan *subset* fitur yang dipilih secara acak. Setiap pohon memiliki aturan pemisahan simpul (*node splitting*) yang berbeda dan bekerja dengan mencari ambang batas terbaik untuk memisahkan data, sehingga menghasilkan banyak model pohon lemah yang memberikan prediksi berbeda[9]. Gabungan dari semua pohon ini digunakan untuk membentuk prediksi akhir yang lebih stabil dan akurat, menjadikan *Random Forest* sebagai solusi yang efektif dalam menangani data kompleks serta membangun model prediktif yang andal [10]. Dalam penelitian ini menggunakan beberapa parameter pengujian, antara lain jumlah pohon (*number of trees*) sebanyak 10, serta jumlah atribut yang dipertimbangkan pada setiap pemisahan (*split*) sebanyak 5. Informasi lebih rinci mengenai parameter yang digunakan pada algoritma *Random Forest* ditampilkan pada Gambar 3.



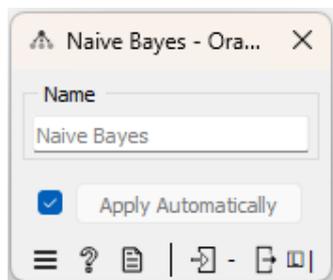
Gambar 3. Parameter Random Forest

3.2.2. Naive Bayes

Naive Bayes merupakan metode statistik berbasis *probabilistic* yang menggunakan pendekatan dari dua penafsiran, yaitu subjektif dan *frequentist*. Dalam pendekatan subjektif, metode ini menjelaskan bagaimana tingkat kepercayaan terhadap suatu hipotesis dapat berubah secara rasional seiring munculnya informasi atau bukti baru. Sementara itu, pendekatan *frequentist* memaknainya sebagai representasi dari *inverse probability* melalui dua skenario kejadian yang berbeda [11]. Metode ini banyak digunakan dalam klasifikasi data karena mampu memperkirakan probabilitas keanggotaan suatu data terhadap kelas tertentu menggunakan *Teorema Bayes*, yang menjadikannya efektif dalam pengolahan himpunan *data training* berukuran besar. Dasar utama dari metode ini adalah *Teorema Bayes*, yang dirumuskan sebagai berikut:[12]

$$P(C|A) = \frac{P(A|C)P(C)}{P(A)} \quad (1)$$

Model ini bekerja dengan menghitung *posterior probability* dari setiap kelas menggunakan distribusi *Gaussian* untuk atribut numerik. Informasi lebih rinci mengenai parameter algoritma ini dapat dilihat pada Gambar 4.

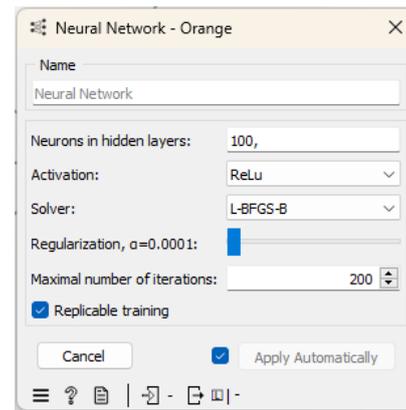


Gambar 4. Parameter Naive Bayes

3.2.3. Neural Network

Neural Network (NN) merupakan algoritma yang terinspirasi dari cara kerja otak manusia dalam memproses informasi, di mana neuron-neuron saling terhubung dan berkomunikasi melalui sinyal [13]. Model *jaringan saraf buatan* pertama kali dikembangkan pada tahun 1943 sebagai representasi matematika sederhana dari struktur neuron biologis. *NN* terdiri dari tiga lapisan utama: *input*, *hidden layer*, dan *output*, yang saling terhubung dalam sistem pemrosesan paralel [14]. Saat ini, *Neural Network* banyak digunakan dalam tugas *classification* dan *regression* karena kemampuannya mengenali pola dan belajar dari data secara efektif [15]. Dalam penelitian ini dilakukan dengan menggunakan sejumlah parameter pengujian, antara lain jumlah neuron pada lapisan tersembunyi (*hidden layer*) sebanyak 100, fungsi aktivasi yang digunakan adalah *ReLU*, serta metode optimasi (*solver*) yang diterapkan yaitu *L-BFGS-B*. Selain itu, diterapkan nilai *regularization* sebesar 0.0001 untuk menghindari *overfitting*, dan

jumlah *training iterations* maksimum ditetapkan sebanyak 200. Informasi lebih rinci mengenai konfigurasi parameter pada algoritma *Neural Network* dapat dilihat pada Gambar 5.



Gambar 5. Parameter Neural Network

3.3. Pengujian Model

Pengujian model dilakukan menggunakan metode *Random Sampling* dengan skema *repeat train/test* sebanyak 10 kali, di mana setiap iterasi menggunakan 80% data sebagai *training set*. Berdasarkan hasil evaluasi, model *Random Forest* menghasilkan nilai *AUC* sebesar 0,995, model *Naive Bayes* menghasilkan nilai *AUC* sebesar 0,980, sementara model *Neural Network* memperoleh nilai *AUC* sebesar 0,957. Rincian lengkap hasil pengujian masing-masing model disajikan pada Tabel 2.

Tabel 2. Pengujian Model

Model	AUC	CA	FI	PREC	RECALL	MCC
Random Forest	0.995	0.989	0.989	0.989	0.989	0.977
Naive Bayes	0.957	0.900	0.900	0.900	0.900	0.790
Neural Network	0.980	0.971	0.971	0.971	0.971	0.938

3.4. Matrik Konfusi

Matriks konfusi merupakan sebuah tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi atau prediksi terhadap data uji yang label aslinya telah diketahui. Matriks ini menyajikan perbandingan silang antara prediksi model terhadap kelas positif dan negatif dengan kondisi aktual dari data [16]. Elemen-elemen utama dalam matriks konfusi meliputi *True Positive (TP)*, *False Positive (FP)*, *False Negative (FN)*, dan *True Negative (TN)*. Keterangan dari empat elemen yang digunakan untuk mengidentifikasi hasil prediksi adalah sebagai berikut [3] :

1. *True Positive (TP)* adalah jumlah data yang secara nyata memiliki kelas positif dan berhasil diprediksi dengan tepat sebagai positif oleh model.
2. *True Negative (TN)* merupakan jumlah data yang secara nyata memiliki kelas negatif dan diprediksi dengan benar sebagai negatif.
3. *False Positive (FP)* adalah jumlah data yang

sebenarnya negatif, namun secara keliru diprediksi sebagai positif oleh model.

4. *False Negative (FN)* adalah jumlah data yang secara nyata positif, namun salah diklasifikasikan sebagai negatif oleh model.

Penyajian lengkap mengenai matriks konfusi ditampilkan pada Tabel 3.

Tabel 3. Matrik Konfusi

Fakta	Prediksi	
Negatif	Negatif (True Negative)	Positif (False Positive)
	TN	FP
Positif	Negatif (False Negative)	Positif (True Positive)
	FN	TP

Terdapat beberapa metrik kinerja yang umumnya digunakan, di antaranya adalah sebagai berikut:

3.4.1. Akurasi

Akurasi merupakan ukuran yang menunjukkan sejauh mana model mampu mengklasifikasikan data dengan benar secara keseluruhan. Nilai akurasi dihitung berdasarkan perbandingan antara jumlah prediksi yang sesuai dengan kondisi aktual terhadap total jumlah data yang diuji. Ukuran ini mencerminkan tingkat ketepatan model dalam melakukan proses klasifikasi [17]. Persentase akurasi pada penelitian ini diperoleh menggunakan rumus sebagai berikut.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

3.4.2. Presisi (Precision)

Presisi, atau *Positive Predictive Value*, merupakan metrik evaluasi yang digunakan untuk mengukur tingkat akurasi prediksi positif dari sebuah model. Presisi dihitung dengan membandingkan jumlah data yang diklasifikasikan secara benar sebagai positif terhadap total prediksi positif, termasuk yang salah (*False Positive*). Nilai ini mencerminkan sejauh mana prediksi positif yang dihasilkan model sesuai dengan kondisi sebenarnya. Semakin banyak prediksi positif yang salah, maka nilai presisi akan semakin menurun [17]. Adapun rumus yang digunakan untuk menghitung nilai presisi adalah sebagai berikut.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

3.4.3. Recall atau Sensitivity

Recall atau sensitivitas merupakan salah satu metode evaluasi yang digunakan untuk menilai kemampuan model dalam mengenali seluruh data yang benar-benar termasuk dalam kelas positif. Nilai recall dihitung dengan membandingkan jumlah data

positif yang berhasil diprediksi dengan benar terhadap total data yang sebenarnya positif. Metrik ini menunjukkan seberapa baik model dalam mendeteksi seluruh kasus positif yang ada [17]. Adapun rumus yang digunakan untuk menghitung nilai Recall atau sensitivitas adalah sebagai berikut:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

3.4.4. F1-Score

F1-Score merupakan metrik evaluasi yang digunakan untuk mengukur keseimbangan antara nilai presisi dan recall. Nilai ini dihitung sebagai rata-rata harmonis dari presisi dan recall, sehingga memberikan gambaran yang lebih menyeluruh terhadap kinerja model, khususnya ketika terdapat ketidakseimbangan data antar kelas. Adapun rumus perhitungan F1-Score adalah sebagai berikut [17]. Adapun rumus yang digunakan untuk menghitung nilai F1-Score adalah sebagai berikut:

$$\text{F1-Score} = 2 \times \frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (5)$$

3.4.5. Nilai Area Under the Curve (AUC)

Area Under the Curve (AUC) merupakan ukuran luas di bawah kurva *ROC (Receiver Operating Characteristic)* yang digunakan untuk menilai performa model klasifikasi. Nilai *AUC* berada dalam rentang 0,5 hingga 1,0, di mana semakin tinggi nilainya menunjukkan semakin baik kinerja model dalam membedakan antara kelas positif dan negatif. Interpretasi nilai *AUC* dapat dibagi menjadi lima kategori, yaitu: 0,5–0,6 (akurasi rendah/salah), 0,6–0,7 (akurasi lemah), 0,7–0,8 (akurasi sedang), 0,8–0,9 (akurasi tinggi), dan 0,9–1,0 (akurasi sangat tinggi) [17]. Adapun penyajian lengkap hasil dari matriks konfusi untuk setiap model klasifikasi, seperti *Random Forest*, *Naive Bayes*, dan *Neural Network*, ditampilkan secara berurutan:

		Predicted		Σ
		negative	positive	
Actual	negative	1009	11	1020
	positive	18	1602	1620
Σ		1027	1613	2640

Gambar 6. Matrik Konfusi Random Forest

Berdasarkan Gambar 6 penggunaan 1.320 data uji, model *Random Forest* berhasil mengklasifikasikan 1009 data “negative” dan 1602 data “positive” dengan benar. Kesalahan klasifikasi terjadi pada 11 data “negative” yang salah diprediksi “positive”, serta 18 data “positive” yang salah diprediksi “negative”. Total

prediksi yang diperoleh adalah 1027 untuk kelas “negative” dan 1613 untuk kelas “positive”.

		Predicted		Σ
		negative	positive	
Actual	negative	967	53	1020
	positive	24	1596	1620
Σ		991	1649	2640

Gambar 7. Matrik Konfusi Naive Bayes

Berdasarkan Gambar 7 penggunaan 1.320 data uji, model *Naive Bayes* berhasil mengklasifikasikan 967 data “negative” dan 1596 data “positive” dengan benar. Kesalahan klasifikasi terjadi pada 53 data “negative” yang salah diprediksi “positive”, serta 24 data “positive” yang salah diprediksi “negative”. Total prediksi yang diperoleh adalah 991 untuk kelas “negative” dan 1649 untuk kelas “positive”.

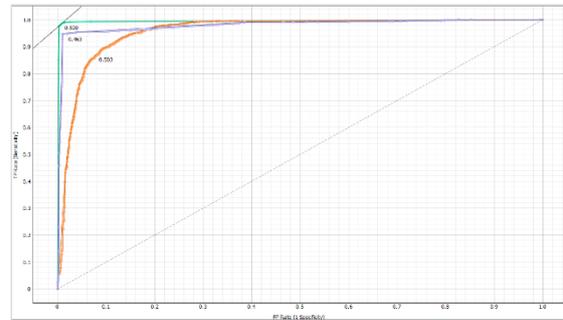
		Predicted		Σ
		negative	positive	
Actual	negative	890	130	1020
	positive	133	1487	1620
Σ		1023	1617	2640

Gambar 8. Matrik Konfusi Naural Network

Berdasarkan Gambar 8 penggunaan 1.320 data uji, model *Neural Network* berhasil mengklasifikasikan 890 data “negative” dan 1487 data “positive” dengan benar. Kesalahan klasifikasi terjadi pada 130 data “negative” yang salah diprediksi “positive”, serta 133 data “positive” yang salah diprediksi “negative”. Total prediksi yang diperoleh adalah 1023 untuk kelas “negative” dan 1617 untuk kelas “positive”.

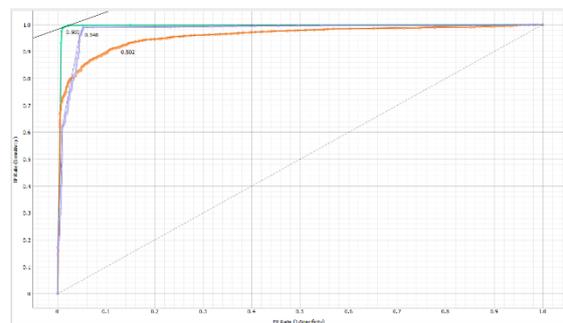
3.5. Hasil Nilai AUC

Hasil klasifikasi penyakit jantung divisualisasikan melalui kurva *ROC*, yang menunjukkan performa model dalam membedakan kategori. Gambar 9 dan 10 menyajikan Kurva *ROC* untuk kategori "negative" (Gambar 9) dengan nilai 0.500 untuk model *Random Forest*, 0.463 untuk model *Naive Bayes* dan 0.513 model *Neural Network*, kategori "positive" (Gambar 10) dengan nilai 0.500 untuk model *Random Forest*, 0.548 untuk model *Naive Bayes* dan 0.502 untuk model *Neural Network* yang merepresentasikan tingkat keakuratan model dalam klasifikasi data.



Gambar 9. Kurva ROC Negative

Gambar 9 memperlihatkan kurva *ROC* yang mengilustrasikan hubungan antara *False Positive Rate* (sumbu x) dan *True Positive Rate* (sumbu y) untuk kategori "negative". Model *Random Forest* memperoleh nilai *AUC* sebesar 0.500, model *Naive Bayes* 0.463 sedangkan model *Neural Network* mencapai 0,513. Nilai ini menjadi dasar dalam mengklasifikasi ketiadaan penyakit jantung. Kesimpulannya, performa model yang mendekati nilai 1.0 tersebut menunjukkan bahwa klasifikasi yang dilakukan memiliki tingkat akurasi yang tinggi.



Gambar 10. Kurva ROC Positive

Gambar 10 memperlihatkan kurva *ROC* yang menunjukkan hubungan antara *False Positive Rate* (sumbu x) dan *True Positive Rate* (sumbu y) untuk kategori "positive". Nilai *AUC* yang diperoleh adalah 0.500 untuk *Random Forest*, 0.548 untuk model *Naive Bayes* dan 0.502 untuk *Neural Network*. Nilai ini digunakan sebagai acuan dalam mengklasifikasi keberadaan penyakit jantung. Dengan demikian, dapat disimpulkan bahwa performa model yang mendekati nilai 1.0 menandakan klasifikasi yang dilakukan memiliki tingkat akurasi yang tinggi.

4. CONCLUSION

Hasil penelitian menunjukkan bahwa ketiga algoritma klasifikasi *Random Forest*, *Naive Bayes*, dan *Neural Network* mampu mengidentifikasi penyakit jantung dengan tingkat akurasi yang tinggi. *Random Forest* memiliki nilai area under the curve (*AUC*) 0,995 dan paling akurat dari ketiga algoritma tersebut. Di sisi lain, algoritma *Naive Bayes* menunjukkan kinerja yang cukup baik dengan perolehan nilai *AUC* sebesar 0,957, walaupun tingkat kesalahannya sedikit lebih

besar dibandingkan dengan Random Forest. Skor F1-, Precision, dan Recall secara konsisten menunjukkan nilai di atas 0,9, yang menunjukkan kemampuan klasifikasi yang kuat dan tingkat kesalahan yang rendah. Meskipun demikian, algoritma Neural Network menunjukkan kinerja yang baik dengan nilai AUC sebesar 0,980, tetapi itu kurang efektif dalam klasifikasi dan lebih akurat daripada kedua algoritma lainnya. Hasil menunjukkan bahwa Random Forest adalah algoritma yang paling efektif untuk membedakan kelas "positif" dan "negatif" dari kumpulan data penyakit jantung yang digunakan. Hasil ini mendukung evaluasi yang dilakukan dengan menggunakan kurva Receiver Operating Characteristic (ROC) dan confusion matrix. Akibatnya, algoritma ini direkomendasikan sebagai cara utama untuk membangun model prediksi penyakit jantung yang lebih akurat dan dapat diandalkan. Penelitian lebih lanjut tentang parameter penyesuaian masing-masing algoritma dan pengujian pada dataset yang lebih besar dan bervariasi diperlukan untuk meningkatkan kemampuan generalisasi dan validitas hasil klasifikasi.

REFERENCES

- [1] I. M. Agus Oka Gunawan, I. D. A. Indah Saraswati, I. D. G. Riswana Agung, and I. P. Eka Putra, "Klasifikasi Penyakit Jantung Menggunakan Algoritma Decision Tree Series C4.5 Dengan Rapidminer," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 2, pp. 73–83, 2023, doi: 10.47233/jteksis.v5i2.775.
- [2] D. Pradana, M. Luthfi Alghifari, M. Farhan Juna, and D. Palaguna, "Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network," *Indonesian Journal of Data and Science*, vol. 3, no. 2, pp. 55–60, 2022, doi: 10.56705/ijodas.v3i2.35.
- [3] H. Hidayat, A. Sunyoto, and H. Al Fatta, "Klasifikasi Penyakit Jantung Menggunakan Random Forest Classifier," *Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan)*, vol. 7, no. 1, pp. 31–40, 2023, doi: 10.47970/siskom-kb.v7i1.464.
- [4] I. Rashad, R. R. Isnanto, and C. E. Widodo, "Klasifikasi Penyakit Jantung Menggunakan Algoritma Analisis Diskriminan Linier," *J. Sistem Info. Bisnis*, vol. 13, no. 1, pp. 29–36, 2023, doi: 10.21456/vol13iss1pp29-36.
- [5] S. A. Putri, N. Selayanti, and M. Kristanaya, "Penerapan Machine Learning Algoritma Random Forest Untuk Prediksi Penyakit Jantung," vol. 2024, no. Senada, 2024.
- [6] A. A. Surya and Y. Yamasari, "Penerapan Algoritma Naïve Bayes (NB) untuk Klasifikasi Penyakit Jantung," *Journal of Informatics and Computer Science (JINACS)*, vol. 5, no. 03, pp. 447–455, 2024, doi: 10.26740/jinacs.v5n03.p447-455.
- [7] J. D. Muthohhar and A. Prihanto, "Analisis Perbandingan Algoritma Klasifikasi untuk Penyakit Jantung," *Journal of Informatics and Computer Science (JINACS)*, vol. 04, pp. 298–304, 2023, doi: 10.26740/jinacs.v4n03.p298-304.
- [8] D. Ade, U. Hayati, T. Hartati, S. L. Manikari, F. Afandi, and S. I. Cirebon, "Jurnal Pengenalan Wajah menggunakan Principle Component Analysis (PCA) dengan Model Algoritma Machine Learning untuk Mengidentifikasi Jenis Kelamin pada Kartu Identitas Mahasiswa Face Recognition using Principle Component Analysis (PCA) with Machine L," *Jurnal Pengenalan Wajah menggunakan Principle Component Analysis (PCA) dengan Model Algoritma Machine Learning untuk Mengidentifikasi Jenis Kelamin pada Kartu Identitas Mahasiswa Face Recognition using Principle Component Analysis (PCA) with Machine L*, vol. 5, pp. 219–224, 2023.
- [9] D. H. Depari, Y. Widiastiwi, and M. M. Santoni, "Perbandingan Model Decision Tree, Naive Bayes dan Random Forest untuk Prediksi Klasifikasi Penyakit Jantung," *Informatik : Jurnal Ilmu Komputer*, vol. 18, no. 3, p. 239, 2022, doi: 10.52958/iftk.v18i3.4694.
- [10] N. Sitohang, "Jurnal Sains Informatika Terapan (JSIT)," *Penerapan Data Mining Untuk Peringatan Dini Banjir Menggunakan Metode Klustering K-Means*, vol. 2, no. 1, pp. 16–20, 2023.
- [11] M. A. Bianto, K. Kusriani, and S. Sudarmawan, "Perancangan Sistem Klasifikasi Penyakit Jantung Menggunakan Naïve Bayes," *Creative Information Technology Journal*, vol. 6, no. 1, p. 75, 2020, doi: 10.24076/citec.2019v6i1.231.
- [12] D. Safitri, S. S. Hilabi, and F. Nurapriani, "Analisis Penggunaan Algoritma Klasifikasi Dalam Prediksi Kelulusan Menggunakan Orange Data Mining," *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 8, no. 1, pp. 75–81, 2023, doi: 10.36341/rabit.v8i1.3009.
- [13] M. R. Adipratama and N. Safriadi, "Analisis Sentimen Terhadap Rencana Penerapan E-Voting Pada Pemilu di Indonesia," *Jurnal Linguistik Komputasional (JLK)*, vol. 7, no. 1, pp. 26–30, 2024, doi: 10.26418/jlk.v7i1.214.
- [14] E. Pranadjaya, E. S. Pangestu, C. O. Sereati, S. Octaviani, and M. Darmawan, "Perbandingan Algoritma Machine Learning menggunakan Orange Data Mining untuk Klasifikasi Jenis Kendaraan pada Sistem

- Tilang Digital,” *Jurnal Elektro*, vol. 17, no. 1, pp. 41–47, 2024, doi: 10.25170/jurnalelektro.v17i1.5429.
- [15] I. Popchev and D. Orozova, “Algorithms for Machine Learning with Orange System,” *International journal of online and biomedical engineering*, vol. 19, no. 4, pp. 109–123, 2023, doi: 10.3991/ijoe.v19i04.36897.
- [16] Sriyanto and A. Ria Supriyatna, “Teknika 17 (1): 163-172 Prediksi Penyakit Diabetes Menggunakan Algoritma Random Forest,” *Ijccs*, vol. x, No.x, no. x, pp. 1–5, 2023.
- [17] D. Kurniawan, M. Wahyudi, and L. Pujiastuti, “Deteksi dan Prediksi Cerdas Penyakit Paru-Paru dengan Algoritma Random Fores,” vol. 3, no. 1, 2024.