

Comparison of accuracy performance of machine learning models for heart disease prediction

Perbandingan Kinerja Akurasi Model Mesin Learning Untuk Prediksi Penyakit Jantung

Juyus Muhammad Adinulhaq¹ dan Muhammad Sam'an^{2,*}

^{1,2}Program Studi Informatika, Fakultas Teknik Universitas Muhammadiyah Semarang, Semarang, Indonesia

Info Artikel

Riwayat Artikel:

Diterima, 2 Januari 2023
Perbaikan, 15 Maret 2023
Disetujui, 29 Juli 2023

Keywords:

Machine learning
Prediction
Logistik regression
Support vector machine
Random forest classifier
Gaussian naïve bayes

ABSTRAK

Penelitian ini bertujuan untuk menganalisis secara komprehensif data terkait penyakit jantung melalui Exploratory Data Analysis (EDA), identifikasi korelasi antara variabel numerik, dan analisis kluster untuk mengungkap pola dalam data. Selanjutnya, menggunakan berbagai algoritma pembelajaran mesin, seperti Logistic Regression, Support Vector Classifier, Decision Tree Classifier, Random Forest Classifier, K-Nearest Neighbors, dan Gaussian Naive Bayes, dilakukan pembangunan model prediksi penyakit jantung. Evaluasi model menunjukkan bahwa Naive Bayes memiliki akurasi pengujian tertinggi sebesar 90%, lalu diikuti Random Forest Classifier dan K-Nearest Neighbors Classifier yang memiliki akurasi pengujian sebesar 85%. Temuan ini menunjukkan kemampuan yang baik dalam memprediksi penyakit jantung, namun perlu dilakukan analisis lebih lanjut untuk memastikan generalisasi yang baik pada data yang tidak terlihat. Penelitian ini memberikan kontribusi penting dalam pengembangan model prediksi penyakit jantung dan dapat mendukung deteksi dini serta strategi intervensi yang tepat.

ABSTRACT

This research aims to comprehensively analyze heart disease-related data through Exploratory Data Analysis (EDA), identification of correlations between numerical variables, and cluster analysis to uncover patterns in the data. Furthermore, using various machine learning algorithms, such as Logistic Regression, Support Vector Classifier, Decision Tree Classifier, Random Forest Classifier, K-Nearest Neighbors, and Gaussian Naive Bayes, a heart disease prediction model was built. The model evaluation shows that Naive Bayes has the highest test accuracy of 90%, followed by RandomForestClassifier and KNeighborsClassifier which have 85% test accuracy. These findings indicate a good ability to predict heart disease, but further analysis is needed to ensure good generalization to unseen data. This research makes an important contribution to the development of heart disease prediction models and can support early detection and appropriate intervention strategies.

Ini adalah artikel akses terbuka di bawah lisensi CC BY-SA.



Penulis Korespondensi:

Muhammad Sam'an
Program Studi Informatika, Fakultas Teknik Universitas Muhammadiyah Semarang
Alamat: Gedung FT-MIPA Lt. 7, Ruang 707, Jl.Kedungmundu Raya No.18, Semarang 50273, Indonesia

1. PENDAHULUAN

Serangan jantung, atau infark miokard [1], terjadi ketika pasokan darah ke bagian otot jantung tidak mencukupi, mengakibatkan kerusakan pada bagian yang terpengaruh karena kekurangan pasokan darah kaya oksigen yang diperlukan. Penyumbatan pada arteri yang membawa darah ke jantung sering menjadi penyebab utama serangan jantung. Kondisi ini dapat meningkatkan risiko gagal jantung dan konsekuensi serius lainnya, karena gangguan pada mekanisme pemompaan jantung yang terjadi ketika sebagian jantung tidak dapat memompa darah secara efisien akibat kurangnya pasokan darah.

Serangan jantung merupakan gangguan jantung yang sangat serius. Gangguan ini terjadi ketika otot jantung tidak mendapatkan aliran darah yang baik. Kondisi inilah yang akan mengganggu fungsi jantung dalam mengalirkan aliran darah ke seluruh tubuh. Hal ini dapat berakibat fatal bagi kesehatan manusia (Fadli, R., 2021). Di Amerika Serikat sendiri penyakit ini dialami oleh 1,5 juta orang setiap tahunnya (Zafari, A.M., 2019). Berdasarkan data dari WHO padatahun 2019 terdapat 17.9 juta kematian yang merupakan akibat dari Cardiovascular Disease atau CVD yang mana angka tersebut mewakili 32% kematian yang ada pada tahun tersebut, selain itu dari total kematian akibat CVD tersebut 85% merupakan korban dari ganasnya penyakit serangan jantung dan stroke ini (WHO, 2021).

Penelitian ini bertujuan untuk melakukan analisis komprehensif terhadap data penyakit jantung dengan menggunakan pendekatan Data Mining. Tahap analisis dimulai dengan melakukan eksplorasi data (EDA) untuk memahami struktur dan karakteristik data yang ada, serta membedakan distribusi fitur individual dan memeriksa hubungan di antara mereka. Selanjutnya, dilakukan analisis korelasi untuk mengeksplorasi potensi hubungan antara variabel numerik dalam dataset dan mengidentifikasi interaksi dan ketergantungan yang signifikan terhadap risiko penyakit jantung. Selain itu, dilakukan analisis kluster untuk mengelompokkan data berdasarkan kesamaan fitur, dengan tujuan mengungkapkan pola atau subkelompok yang mendasari dalam data, yang mungkin menjadi indikasi kelompok risiko tertentu atau profil penyakit jantung.

Selanjutnya, penelitian ini melibatkan pengembangan model prediktif menggunakan berbagai algoritme pembelajaran mesin. Tujuannya adalah untuk memprediksi diagnosis penyakit jantung berdasarkan fitur yang ada dalam dataset, dengan fokus pada deteksi dini dan strategi intervensi. Beberapa algoritme yang dievaluasi dalam penelitian ini meliputi Logistic Regression, Support Vector Classifier (SVC), Decision Tree Classifier, Random Forest Classifier, K-Nearest Neighbors (KNN), dan Gaussian Naive Bayes. Kinerja model-model ini dievaluasi berdasarkan akurasi pelatihan dan pengujiannya.

Judul artikel harus terdiri dari kata-kata sesedikit mungkin yang secara akurat menggambarkan isi makalah. Judul harus ringkas dan informatif dan tidak lebih dari 12 kata. Jangan gunakan singkatan atau akronim dalam judul dan jangan menyebutkan metode yang Anda gunakan, kecuali jika makalah Anda melaporkan pengembangan metode baru. Judul sering kali digunakan dalam sistem pencarian informasi. Hindari penulisan rumus yang panjang dengan subskrip pada judul. Hilangkan semua kata-kata yang tidak berguna seperti "Sebuah studi tentang ...", "Investigasi tentang ...", "Implementasi ...", "Pengamatan tentang ...", "Pengaruh dari.....", "Analisis ...", "Desain ...", dan lain-lain.

Diperlukan abstrak yang ringkas dan faktual. Abstrak harus menyatakan secara singkat tujuan penelitian, hasil utama, dan kesimpulan utama. Abstrak sering kali disajikan secara terpisah dari artikel, sehingga harus dapat berdiri sendiri. Untuk alasan ini, Referensi harus dihindari, tetapi jika penting, maka kutiplah penulis dan tahun. Selain itu, singkatan yang tidak standar atau tidak umum harus dihindari, tetapi jika penting, singkatan tersebut harus dijelaskan pada saat pertama kali disebutkan dalam abstrak. Segera setelah abstrak, berikan maksimal 7 kata kunci, dengan menggunakan ejaan Amerika dan hindari istilah umum dan jamak serta beberapa konsep (hindari, misalnya, 'dan', 'dari'). Hematlah dalam menggunakan singkatan: hanya singkatan yang sudah mapan di bidangnya yang memenuhi syarat. Kata kunci ini akan digunakan untuk tujuan pengindeksan.

Layanan pengindeksan dan pengabstraksian bergantung pada keakuratan judul, mengekstrak kata kunci yang berguna dalam referensi silang dan pencarian komputer. Makalah yang diberi judul yang tidak tepat mungkin tidak akan pernah sampai ke pembaca yang dituju, jadi buatlah judul yang spesifik.

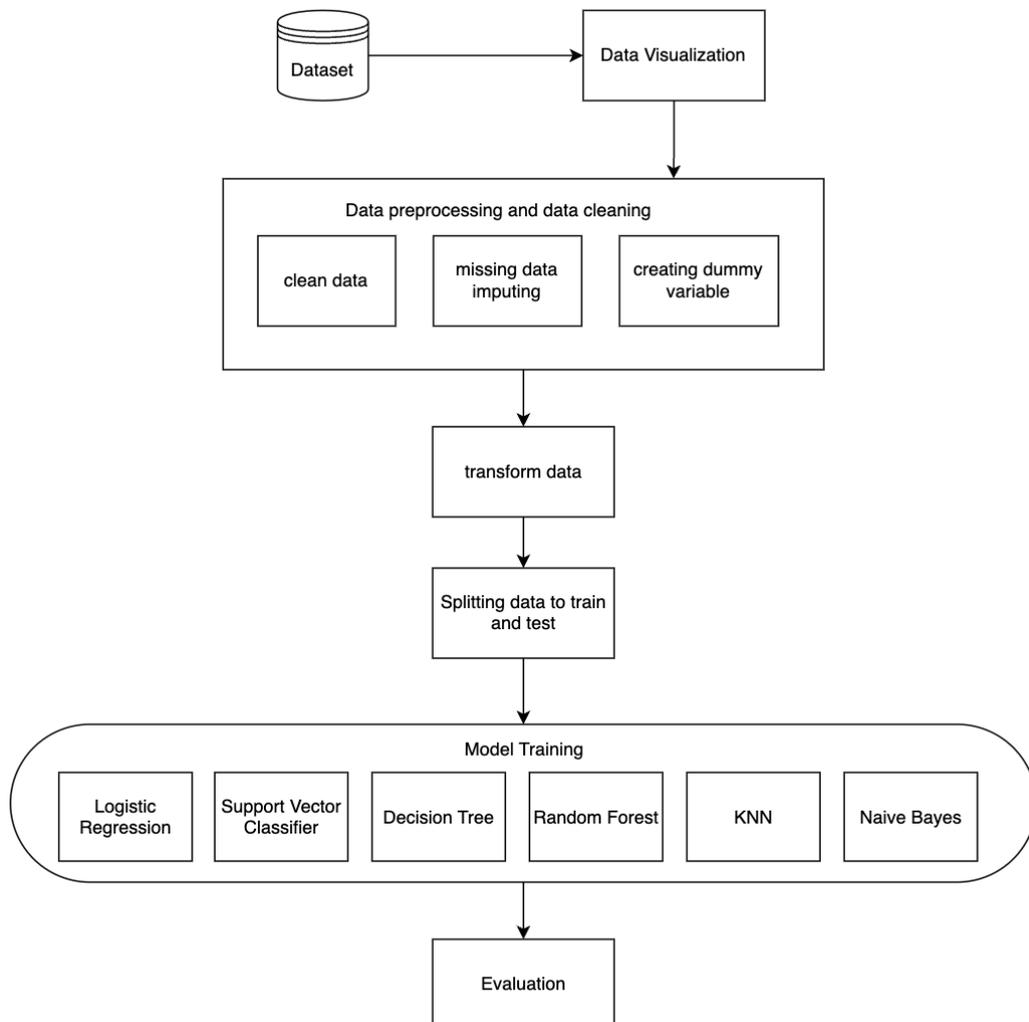
2. METODE

2.1. Jenis dan Sumber Data

Jenis data yang digunakan pada penelitian ini adalah data sekunder yang berupa data numerik dan kategorikal. Adapun data yang digunakan terdiri dari data kategorikal dan numerik, data yang digunakan memberikan gambaran menyeluruh tentang faktor-faktor yang berpotensi menyebabkan penyakit jantung, termasuk detail demografis seperti *age* dan *sex*, *clinical parameters like chest pain type (cp)*, *resting blood pressure (trtbps)*, *serum cholesterol (chol)*, *fasting blood sugar (fbs)*, dan *resting electrocardiographic results (restecg)*, dll, yang diperoleh dari <https://www.kaggle.com/datasets/rashikrahmanpritom/heart-attack-analysis-prediction-dataset>.

2.2. Data preprocessing

Model pembelajaran mesin (ML) [2] dikembangkan dan dilatih berdasarkan data asli, kinerja dan kemampuan belajar model tersebut dapat dipengaruhi oleh kualitas data yang buruk. Oleh karena itu, tahap pra-pemrosesan data menjadi sangat penting dalam teknik ML, di mana data mentah diubah menjadi format yang dapat dipahami. Penelitian ini menerapkan teknik pra-pemrosesan data untuk memastikan bahwa model yang dihasilkan mencapai performa terbaik. Tahap awal yang dilakukan adalah analisis data eksplorasi (EDA) [3] untuk mendapatkan pemahaman yang mendalam tentang dataset. EDA melibatkan visualisasi yang komprehensif dan ringkasan data mentah. Selanjutnya, dilakukan anonimisasi data dengan menghapus informasi yang dapat mengidentifikasi, seperti nomor kasus, dari kumpulan data. Penelitian ini juga memeriksa bahwa semua fitur dalam dataset tidak memiliki nilai yang hilang atau tidak terjawab.



Gambar 1. Penerapan Metodologi untuk Pengembangan Model

Persentase nilai yang hilang di semua variabel dalam *dataset* dihitung. Selanjutnya, imputasi data yang hilang digunakan untuk menangani data yang terlewat dan nilai nol. Dalam *dataset*, tiga variabel dikeluarkan karena memiliki persentase data yang hilang yang tinggi pada tahap ini. Untuk menghubungkan data yang

hilang, mengganti nilai yang hilang dengan rata-rata pengamatan yang tidak hilang digunakan untuk variabel kontinu. Nilai kategori ditangani menggunakan Label Encoder untuk mengubahnya menjadi nilai numerik.

2.3. Pengembangan Model dan Evaluasi

Karena fokus utama dari penelitian ini adalah untuk memprediksi serangan jantung, maka penelitian ini menggunakan teknik *supervised machine learning*. Model pembelajaran mesin dilatih menggunakan variabel input dan mempelajari pola dari data pelatihan untuk mengklasifikasikan instansi. Dataset dibagi menjadi data pelatihan sebesar 80% dan data pengujian sebesar 20%. Setelah melalui proses pelatihan, selanjutnya mengevaluasi performa masing-masing model pengklasifikasi menggunakan data pengujian menggunakan bahasa pemrograman Python [4]. Enam model klasifikasi yang dipilih dalam analisis pembelajaran mesin ini.

2.4. Logistic Regression

Regresi logistik [5] merupakan suatu metode regresi yang digunakan untuk melakukan klasifikasi pada output yang bersifat biner. Dengan kata lain, model ini dapat digunakan untuk memprediksi variabel yang hanya memiliki dua kategori, yaitu kejadian dan tidak kejadian.

2.5. Support Vector Machine

SVM [6] adalah algoritma pembelajaran mesin yang digunakan untuk tugas klasifikasi dan regresi. SVM mencoba membuat garis atau permukaan pemisah yang optimal antara dua kelas berdasarkan titik-titik data yang disebut "vektor pendukung" di antara kedua kelas tersebut. SVC adalah implementasi khusus dari SVM untuk tugas klasifikasi, di mana SVM digunakan untuk mengklasifikasikan data ke dalam dua atau lebih kelas berdasarkan fitur-fiturnya. Jadi, SVM dan SVC dapat dianggap sama dalam konteks tugas klasifikasi.

2.6. Decision Tree

Decision Tree Classifier [7] mengelompokkan dataset menjadi subset yang lebih kecil dalam bentuk struktur pohon untuk memisahkan data berdasarkan karakteristik yang berbeda. Metode ini memiliki potensi untuk mengatasi volume informasi yang besar. Dalam Decision Tree Classifier, simpul dan cabang dibentuk dalam pohon untuk memecah data. Ini dapat digunakan baik untuk masalah regresi maupun klasifikasi. Setiap simpul dalam pohon berfungsi sebagai kasus uji untuk satu atau beberapa fitur. Setiap cabang simpul terkait dengan kemungkinan respons dari kasus uji. Proses ini dilakukan secara rekursif untuk setiap subtree dari simpul akar. Decision Tree Classifier menggunakan perhitungan untuk mendapatkan informasi dari setiap pohon untuk membagi simpul. Dua teknik utama yang digunakan untuk menghitung informasi yang didapat adalah entropi dan indeks Gini. Kedua metrik tersebut mengukur tingkat ketidakmurnian dalam sebuah simpul. Berikut ini adalah rumus untuk menghitung entropi dan indeks Gini pada setiap simpul. Dalam kedua rumus tersebut, $p(c_i)$ mengacu pada probabilitas atau persentase kelas c_i dalam sebuah simpul.

$$Gini = 1 - \sum_{i=1}^n p(c_i)^2$$

$$Entropy = \sum_{i=1}^n -p(c_i) \log_2(p(c_i))$$

2.7. Random Forest

Random forest (RF) [8] adalah suatu metode pengklasifikasi ansambel yang terdiri dari sejumlah besar pengklasifikasi pohon acak yang diterapkan pada kumpulan data input. Teknik ini dapat digunakan untuk mengukur pentingnya relatif setiap fitur dalam model prediksi yang dibangun. Random forest dapat mengatasi volume data yang besar dan juga cocok untuk kumpulan data yang memiliki bias.

2.8. KNN

K-Nearest Neighbors (KNN) [9] adalah salah satu metode klasifikasi yang paling sederhana dalam pembelajaran mesin yang berbasis pada konsep kesamaan fitur. Tujuannya adalah untuk memprediksi nilai dari instance baru dalam kategori dengan melihat kesamaan dengan tetangga terdekatnya. KNN tidak melibatkan proses pembelajaran langsung dari data latih, sehingga disebut juga sebagai algoritma "lazy learner" atau algoritma malas. Dalam KNN, jarak, terutama jarak Euclidean, dihitung antara setiap titik data dan data uji untuk menentukan probabilitas keanggotaan titik tersebut. Salah satu hal penting dalam algoritma ini adalah pemilihan jumlah tetangga yang akan digunakan dalam proses prediksi.

2.9. Gaussian Naive Bayes

Gaussian Naive Bayes [10] adalah sebuah algoritma yang berdasarkan pada teorema Bayes, yang menggunakan probabilitas bersyarat untuk memecahkan masalah klasifikasi. Dalam algoritma ini, dilakukan prediksi probabilitas keanggotaan untuk setiap kelas, yaitu probabilitas titik data terkait dengan kelas tertentu. Algoritma ini digunakan khususnya untuk distribusi data binomial (normal) dalam mengklasifikasikan variabel target.

2.10. Model Evaluasi

Model klasifikasi digunakan untuk memperkirakan kelas target dalam dataset. Model ini menghasilkan prediksi probabilitas untuk setiap sampel yang terkait dengan kelas target. Penting untuk mengevaluasi kinerja model klasifikasi agar dapat digunakan secara efektif dalam menyelesaikan masalah dunia nyata. Dalam pembelajaran mesin, berbagai metrik digunakan untuk mengevaluasi kinerja model klasifikasi. Pertama, kita dapat menghasilkan matriks kebingungan dengan menghitung True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN) untuk setiap pengklasifikasi. Terutama pada data yang tidak seimbang, matriks kebingungan memberikan wawasan tambahan tentang kinerja model prediksi dan dapat menunjukkan sampel yang diklasifikasikan dengan benar dan yang salah. Selain itu, metrik evaluasi seperti akurasi, spesifisitas, sensitivitas, Recall, dan F-Measure dapat dihitung dari sel-sel dalam matriks kebingungan. Berikut adalah rumus-rumus yang digunakan untuk menghitung metrik-metrik tersebut.

$$\text{Accuracy} = \frac{\text{True Positive (TP)} + \text{True Negative (TN)}}{\text{All predictions outcomes}}$$

$$\text{Specificity} = \frac{\text{True Negative}}{\text{True Negative (TN)} + \text{False Positive (FP)}}$$

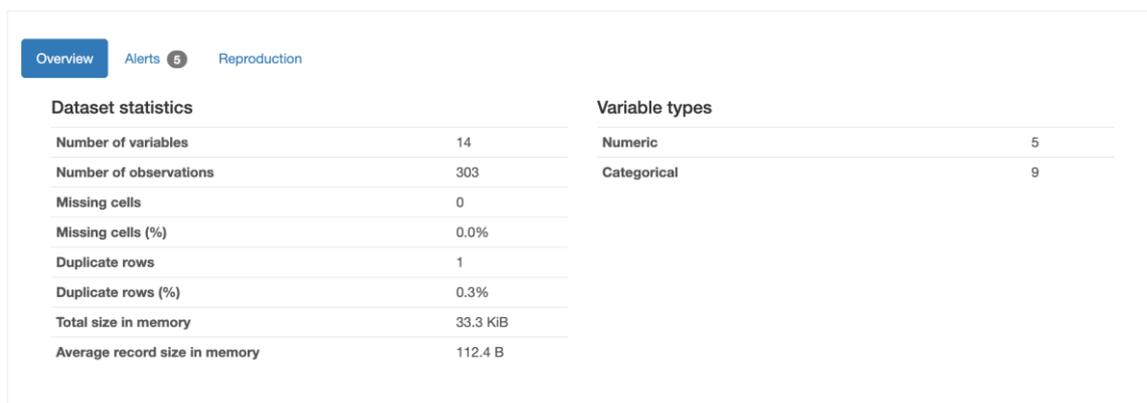
$$\text{Recall} = \frac{\text{True Positive (TP)}}{\text{True Positive (TP)} + \text{False Negative (FN)}}$$

$$\text{F1 or F - Measure} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}}$$

3. HASIL DAN PEMBAHASAN

Dataset terdiri dari 14 variabel dan 303 observasi. Terdapat 1 duplikat baris, setelah mengetahui adanya duplikat baris, langkah yang diambil adalah melakukan penghapusan baris yang mengandung duplikat. Penghapusan dilakukan untuk memastikan kualitas dan keakuratan data yang digunakan dalam analisis. Dengan demikian, dataset yang akan digunakan selanjutnya akan terbebas dari duplikat.

Overview



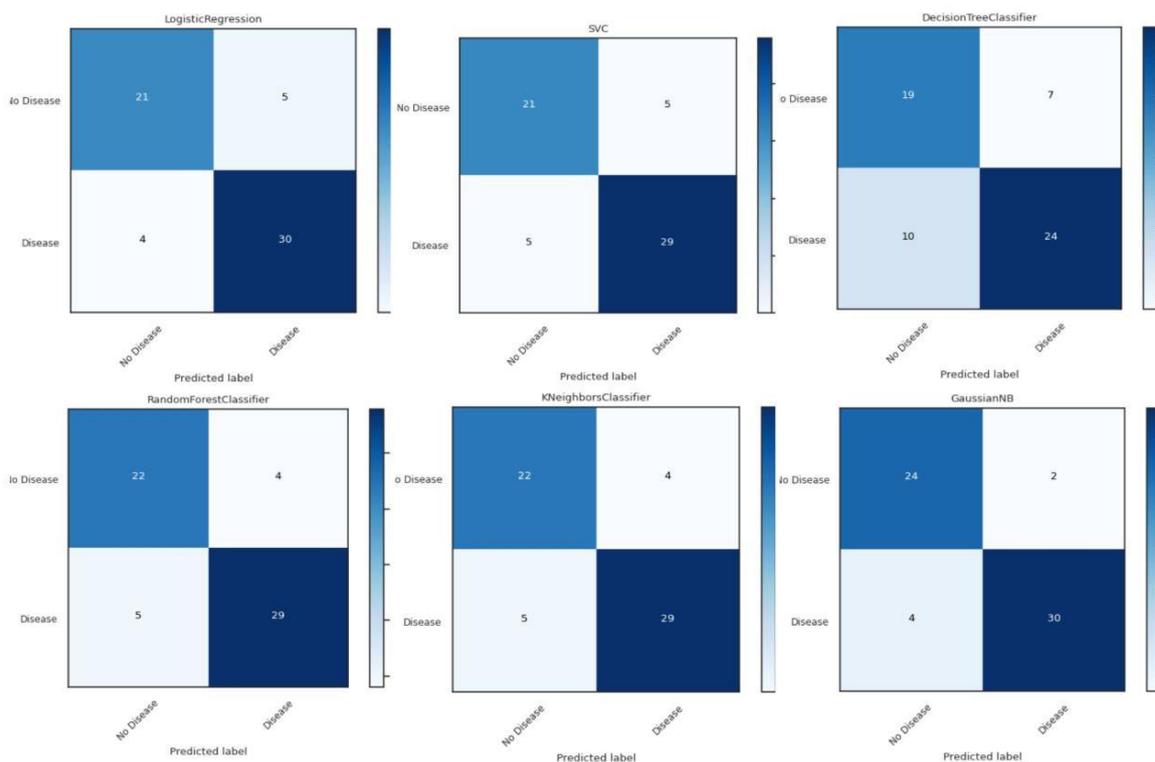
Dataset statistics		Variable types	
Number of variables	14	Numeric	5
Number of observations	303	Categorical	9
Missing cells	0		
Missing cells (%)	0.0%		
Duplicate rows	1		
Duplicate rows (%)	0.3%		
Total size in memory	33.3 KiB		
Average record size in memory	112.4 B		

Gambar 2. Ringkasan Dataset

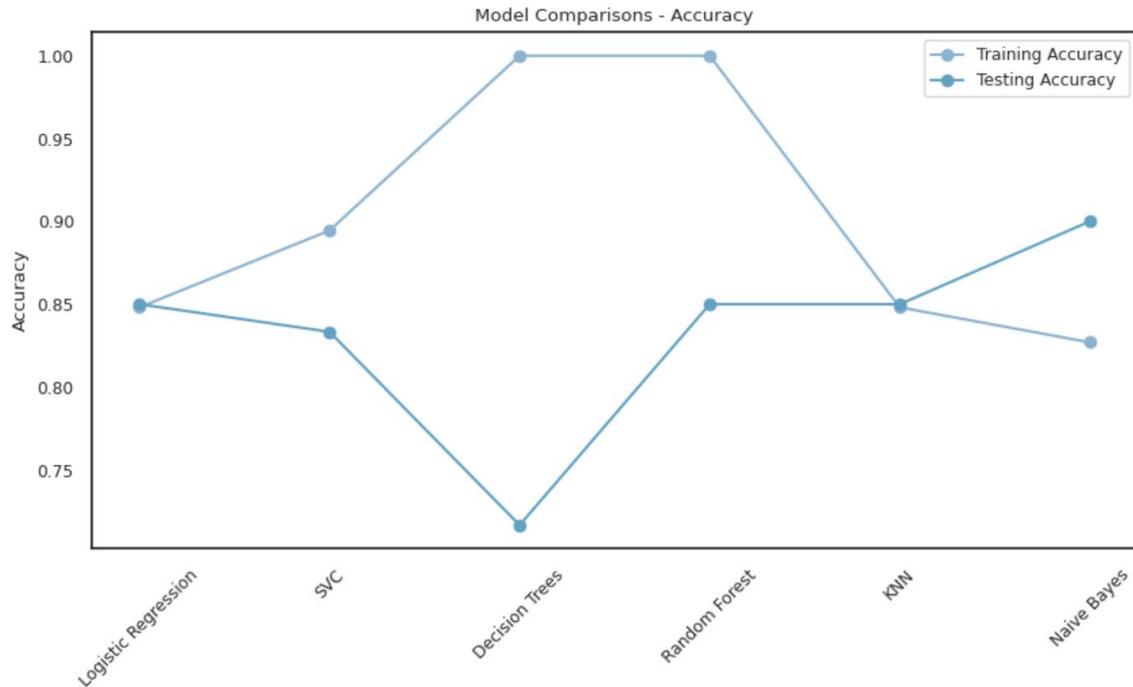
Setelah melalui tahap preprocessing data dan seleksi fitur, berbagai model machine learning (ML) seperti Logistic Regression (LR), Gaussian Naive Bayes (NB), K-Nearest Neighbors (KNN), Decision Tree (DT), Random Forest (RF), dan XGBoost (XGB) dikembangkan untuk membangun model akhir menggunakan bahasa Python. Evaluasi kinerja model-model ini dilakukan dengan menggunakan matriks kebingungan (*Confusion Matrix*) pada tahap awal.

Model Logistic Regression (LR) memiliki akurasi pelatihan sebesar 85% dan akurasi pengujian sebesar 85%. Hal ini menunjukkan bahwa model tersebut mampu digeneralisasikan dengan baik pada data yang belum pernah dilihat sebelumnya dan tidak terjadi overfitting terhadap data pelatihan. Model Support Vector Classifier (SVC) mencapai akurasi pelatihan sebesar 90% dan akurasi pengujian sebesar 84%. Meskipun model ini bekerja dengan baik pada data pelatihan, namun terdapat sedikit kesulitan dalam menggeneralisasi pada data pengujian. Decision Tree Classifier mencapai akurasi pelatihan sempurna 100%, namun akurasi pengujian turun menjadi 72%. Hal ini menunjukkan bahwa model decision tree cenderung terjadi overfitting pada data pelatihan dan tidak mampu menggeneralisasi dengan baik pada data pengujian. Model Random Forest Classifier juga mencapai akurasi pelatihan sempurna 100%, dan memiliki akurasi pengujian sebesar 85%. Hal ini menunjukkan bahwa model random forest lebih baik dalam menggeneralisasi data dibandingkan dengan model decision tree. K-Nearest Neighbors (KNN) memiliki akurasi pelatihan sebesar 85% dan akurasi pengujian sebesar 85%. Hasil ini menunjukkan bahwa model KNN mampu menggeneralisasi data pengujian dengan baik dan memberikan prediksi yang akurat. Model Gaussian Naive Bayes (NB) mencapai akurasi pelatihan sebesar 83% dan akurasi pengujian sebesar 90%. Model ini menunjukkan kinerja yang baik pada kedua set data, baik pada data pelatihan maupun pengujian.

Dengan demikian, hasil evaluasi ini memberikan pemahaman tentang perbandingan kinerja model-model pembelajaran mesin yang telah dikembangkan dan menemukan model-model yang memiliki kemampuan yang baik dalam menggeneralisasi dan memberikan prediksi yang akurat pada dataset yang digunakan.



Gambar 3. Hasil Confusion Matrix



Gambar 4. Perbandingan Model Pembelajaran Mesin

Tabel 1. Perbandingan Model Pembelajaran Mesin

Model	Training Accuracy	Testing Accuracy
Logistic Regression	0,848101	0,850000
Support Vector Classifier	0,894515	0,833333
Decision Trees	1,000000	0,716667
Random Forest	1,000000	0,850000
KNN	0,848101	0,850000
Naive Bayes	0,827004	0,900000

4. KESIMPULAN DAN SARAN

4.1. Kesimpulan

Berdasarkan hasil pengujian, Naive bayes mencapai akurasi pengujian tertinggi sebesar 90%, SupportVectorClassifier dan KNN mencapai akurasi pengujian tertinggi sebesar 85%, menunjukkan bahwa ketiga model ini sangat efektif dalam memprediksi penyakit jantung berdasarkan kumpulan data yang diberikan. Namun, perlu dilakukan analisis lebih lanjut untuk memastikan bahwa model-model ini dapat menggeneralisasi dengan baik pada data yang belum terlihat dan untuk mengoptimalkan performa mereka. Selain itu, dalam memilih model yang tepat, juga perlu mempertimbangkan faktor lain seperti interpretabilitas dan kompleksitas model, serta melakukan penelitian lebih lanjut dengan dataset yang lebih luas dan menggunakan teknik validasi silang untuk memperoleh estimasi performa yang lebih akurat dan konsisten.

4.2. Saran

Berdasarkan hasil evaluasi model, disarankan untuk melanjutkan penelitian dengan fokus pada model Support Vector Classifier (SVC) dan K-Nearest Neighbors (KNN) yang menunjukkan akurasi pengujian tertinggi. Langkah selanjutnya dapat mencakup penyesuaian hyperparameter dan validasi silang untuk meningkatkan kinerja model secara keseluruhan. Selain itu, perlu dilakukan analisis lebih lanjut untuk mengidentifikasi faktor-faktor yang berkontribusi terhadap akurasi yang tinggi dan memastikan generalisasi yang baik pada dataset yang tidak terlihat sebelumnya. Dengan pendekatan ini, diharapkan model dapat lebih dioptimalkan dan dapat digunakan dengan lebih baik dalam konteks praktis.

REFERENSI

- [1] M. W. Rasheed, A. Mahboob, and I. Hanif, "An estimation of physicochemical properties of heart attack treatment medicines by using molecular descriptor's," *S Afr J Chem Eng*, vol. 45, pp. 20–29, Jul. 2023, doi: 10.1016/j.sajce.2023.04.003.
- [2] Y. Gong, G. Liu, Y. Xue, R. Li, and L. Meng, "A survey on dataset quality in machine learning," *Inf Softw Technol*, vol. 162, Oct. 2023, doi: 10.1016/j.infsof.2023.107268.
- [3] P. Chakri, S. Pratap, Lakshay, and S. K. Gouda, "An exploratory data analysis approach for analyzing financial accounting data using machine learning," *Decision Analytics Journal*, vol. 7, Jun. 2023, doi: 10.1016/j.dajour.2023.100212.
- [4] R. Kozakai, T. Kobayashi, Z. Wenxuan, and Y. Watanabe, "Tendency Analysis of Python Programming Classes for Junior and Senior High School Students," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 4603–4612. doi: 10.1016/j.procs.2022.09.524.
- [5] S. Asgharieh Ahari and B. Kocuk, "A mixed-integer exponential cone programming formulation for feature subset selection in logistic regression," *EURO Journal on Computational Optimization*, vol. 11, p. 100069, 2023, doi: 10.1016/j.ejco.2023.100069.
- [6] D. K. Jana, P. Bhunia, S. Das Adhikary, and A. Mishra, "Analyzing of salient features and classification of wine type based on quality through various neural network and support vector machine classifiers," *Results in Control and Optimization*, vol. 11, Jun. 2023, doi: 10.1016/j.rico.2023.100219.
- [7] A. Subasi, A. Ahmed, and E. Alickovic, "Effect of flash stimulation for migraine detection using decision tree classifiers," in *Procedia Computer Science*, Elsevier B.V., 2018, pp. 223–229. doi: 10.1016/j.procs.2018.10.332.
- [8] X. Ma *et al.*, "Predicting the utilization factor of blasthole in rock roadways by random forest," *Underground Space (China)*, vol. 11, pp. 232–245, Aug. 2023, doi: 10.1016/j.undsp.2023.01.006.
- [9] H. Kaneko, "Local interpretation of nonlinear regression model with k-nearest neighbors," *Digital Chemical Engineering*, vol. 6, Mar. 2023, doi: 10.1016/j.dche.2022.100078.
- [10] A. Pérez, P. Larrañaga, and I. Inza, "Supervised classification with conditional Gaussian networks: Increasing the structure complexity from naive Bayes," *International Journal of Approximate Reasoning*, vol. 43, no. 1, pp. 1–25, Sep. 2006, doi: 10.1016/j.ijar.2006.01.002.