

Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi)

DOI: <https://doi.org/10.35870/jtik.v10i1.4900>

Analisis Komparatif Kinerja Algoritma *Support Vector Machine* (SVM) dan *LightGBM* untuk Klasifikasi Penyakit Jantung

Muzakkir Pangri¹, Muhammad Yusuf^{2*}, Indah Purnama Sari³, Waode Faizah Zahra N⁴

^{1,2*,3,4} Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Sorong, Kota Sorong, Provinsi Papua Barat Daya, Indonesia.

article info

Article history:

Received 11 July 2025

Received in revised form

20 July 2025

Accepted 30 September 2025

Available online January

2026.

Keywords:

Classification; Heart Disease
Prediction; SVM; LightGBM.

abstract

Heart disease remains one of the leading causes of death worldwide, making early detection and accurate classification essential to mitigating greater health risks. This study presents a comparative analysis of two machine learning algorithms Support Vector Machine (SVM) and Light Gradient Boosting Machine (LightGBM) for heart disease classification. The dataset used is the UCI Heart Disease dataset, comprising 920 patient records. Model performance was evaluated using accuracy, precision, recall, and F1-score metrics. Experimental results indicate that the SVM model achieved the highest accuracy at 84%, along with an F1-score of 86% for the positive class and a recall of 92%. In contrast, LightGBM demonstrated balanced performance, achieving 83% accuracy and an F1-score of 85%. These findings suggest that SVM holds a slight advantage in identifying heart disease cases, particularly in minimizing false negatives an aspect that is critical yet often overlooked in prior comparative studies.

abstract

Penyakit jantung merupakan salah satu penyebab utama kematian di seluruh dunia, sehingga diperlukan deteksi dini dan klasifikasi yang tepat untuk mencegah risiko yang lebih besar. Studi ini membandingkan performa dua algoritma machine learning, yaitu Support Vector Machine (SVM) dan Light Gradient Boosting Machine (LightGBM), dalam tugas klasifikasi penyakit jantung. Data yang digunakan berasal dari dataset UCI Heart Disease dengan total 920 data pasien. Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil eksperimen menunjukkan bahwa SVM meraih akurasi tertinggi sebesar 84% dan F1-score sebesar 86% pada kelas positif, serta recall sebesar 92%. Di sisi lain, LightGBM menunjukkan performa yang cukup seimbang dengan akurasi 83% dan F1-score 85%. Temuan ini mengindikasikan bahwa SVM memiliki keunggulan dalam mengidentifikasi pasien dengan penyakit jantung, terutama dalam mengurangi false negative, yang merupakan aspek penting namun kerap diabaikan dalam penelitian serupa.

Corresponding Author. Email: yusuf@um-sorong.ac.id ^{2}.

Copyright 2026 by the authors of this article. Published by Lembaga Otonom Lembaga Informasi dan Riset Indonesia (KITA INFO dan RISET). This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License. 

1. Pendahuluan

Jantung merupakan organ vital dalam tubuh manusia yang memiliki peran utama dalam menjaga kelangsungan sistem sirkulasi darah. Sebagai inti dari sistem ini, jantung berfungsi sebagai pompa biologis yang bekerja tanpa henti untuk mendistribusikan darah ke seluruh tubuh, memastikan pasokan darah yang cukup untuk semua jaringan tubuh (Dian *et al.*, 2021). *Coronary Artery Disease* (Penyakit Jantung Koroner/PJK) adalah gangguan kesehatan yang disebabkan oleh kerusakan pada lapisan dalam arteri koroner, yang dapat menyebabkan penyempitan atau penyumbatan pembuluh darah (Tampubolon *et al.*, 2023). Penyakit jantung adalah penyebab utama kematian di dunia, dengan sekitar 17,5 juta orang meninggal setiap tahun akibat penyakit kardiovaskular, dan sekitar 7,4 juta di antaranya disebabkan secara khusus oleh PJK (World Health Organization, 2021). Di Indonesia, PJK merupakan penyebab kematian kedua terbesar setelah stroke, yang paling banyak menyerang kelompok usia lanjut dan masyarakat berpendapatan rendah. PJK terjadi akibat kerusakan pada dinding dalam pembuluh darah arteri koroner, yang menghambat aliran darah akibat penyempitan atau sumbatan. Mengingat tinggi risiko komplikasi, deteksi dini sangat penting untuk pengelolaan dan penanganan penyakit jantung yang lebih efektif (Asmianto *et al.*, 2022). Pencegahan *Coronary Artery Disease* (PJK) menjadi langkah utama dalam menurunkan angka kejadian dan mengurangi risiko komplikasi penyakit kardiovaskular. Upaya pencegahan lebih banyak difokuskan pada pengelolaan faktor-faktor risiko yang masih dapat dikendalikan, seperti hipertensi, dislipidemia, diabetes, obesitas, kebiasaan merokok, stres, dan pola

hidup yang tidak sehat (Erawati, 2021). Salah satu pendekatan yang terbukti efektif dalam menangani pasien penyakit jantung adalah program rehabilitasi jantung. Program ini mencakup beberapa aspek penting, seperti pemeriksaan medis, latihan fisik terstruktur, edukasi tentang pola hidup sehat, dan dukungan psikososial. Tujuan utama dari program ini adalah untuk mengurangi risiko kekambuhan, meningkatkan fungsi jantung, serta memperbaiki kualitas hidup pasien secara berkelanjutan (Azzahra', 2024). Seiring dengan kemajuan *machine learning*, algoritma yang lebih efisien kini diterapkan untuk meningkatkan kinerja klasifikasi (Asif *et al.*, 2023; Yi *et al.*, 2024). Namun, masih terdapat peluang untuk penelitian lebih lanjut terhadap algoritma modern yang efisien dan sensitif, terutama dalam mengurangi *false negatives*, yang sangat penting dalam diagnosis penyakit jantung (Ahmad & Polat, 2023). Penelitian ini mengadopsi pendekatan yang lebih maju dengan menerapkan dua algoritma mutakhir, yakni *Support Vector Machine* (SVM) dan *Light Gradient Boosting Machine* (LightGBM). Berbeda dengan studi sebelumnya, penelitian ini membandingkan secara langsung SVM dan LightGBM, di mana SVM mencatatkan *recall* sebesar 92%, melampaui algoritma klasik dan bahkan menunjukkan sensitivitas diagnostik yang lebih baik dibandingkan model ensemble terbaik dalam studi terkait. LightGBM juga menunjukkan hasil yang baik dengan akurasi 83% dan *F1-score* 85%. Temuan ini menunjukkan bahwa model yang dikembangkan dalam penelitian ini memiliki tingkat keandalan diagnostik yang lebih tinggi, terutama dalam mengidentifikasi kasus positif secara lebih akurat, sehingga lebih cocok diterapkan dalam praktik diagnosis klinis.

Tabel 1. Penelitian Terdahulu

No	Peneliti (Tahun)	Algoritma Digenunakan	Dataset	Hasil	Catatan/Perbandingan dengan Penelitian Ini
1	(Nurrokhman, 2023)	<i>Support Vector Machine</i> (SVM), <i>Naïve Bayes</i>	Tidak disebutkan	SVM unggul dengan <i>recall</i> 88%	Penelitian ini membandingkan SVM dengan LightGBM, di mana SVM mencapai <i>recall</i> 92%, menunjukkan kapabilitas diagnostik yang lebih baik.
2	(Pratama <i>et al.</i> , 2024)	K-Nearest Neighbor (KNN), <i>Naïve Bayes</i>	UCI Heart Disease	Akurasi terbaik 82,76%, <i>recall</i> 83,33%	Penelitian ini menggunakan algoritma modern (SVM dan LightGBM) yang melampaui

					performa model klasik, dengan akurasi SVM 84% dan <i>recall</i> 92%.
3	(Khan Mamun & Elfouly, 2023)(Khan Mamun & Elfouly, 2023)	8 algoritma klasifikasi (termasuk RF, XGB)	Tidak disebutkan spesifik	Random Forest dan XGBoost terbaik: akurasi 91,80%, <i>recall</i> 90,32%	Meskipun membandingkan SVM dan LightGBM, penelitian ini menunjukkan bahwa SVM dalam studi ini mencapai <i>recall</i> lebih tinggi (92%) dibanding model ensemble terbaik mereka.
4	(Sepharni <i>et al.</i> , 2022)	C4.5, Regresi Logistik	Tidak disebutkan spesifik	Regresi Logistik terbaik: akurasi 84,81%, <i>recall</i> 84,8%	Penelitian ini menunjukkan SVM memiliki <i>recall</i> 92%, menandakan kemampuan yang lebih andal dalam mendeteksi kasus positif dibandingkan Regresi Logistik dalam studi terdahulu.

Dari tinjauan penelitian terdahulu yang terdapat dalam Tabel 1, berbagai algoritma *machine learning* telah diterapkan dalam klasifikasi penyakit jantung dengan tingkat keberhasilan yang bervariasi. Beberapa studi menunjukkan akurasi tinggi, namun perhatian pada minimisasi *false negatives* yang memiliki dampak besar dalam diagnosis medis sering kali masih menjadi aspek yang kurang mendapat perhatian dan perlu diperhatikan lebih lanjut. Penelitian ini fokus pada perbandingan antara *Support Vector Machine* (SVM) dan *Light Gradient Boosting Machine* (LightGBM), dua algoritma modern yang efisien, dengan penekanan pada kemampuan keduanya untuk mendeteksi kasus positif dengan akurat serta meminimalkan kesalahan diagnosis yang dapat berisiko.

Support Vector Machine (SVM) adalah salah satu algoritma *machine learning* yang populer digunakan dalam tugas klasifikasi. Prinsip dasar SVM adalah mencari garis pemisah terbaik (optimal hyperplane) yang memisahkan dua kelas data secara maksimal dalam ruang fitur (Baldomero-Naranjo *et al.*, 2021). Hyperplane ini ditentukan dengan memaksimalkan margin, yaitu jarak antara garis pemisah dan data yang paling dekat dari masing-masing kelas. Data yang paling dekat dengan hyperplane dan berperan dalam penentuan posisinya disebut *support vectors*. Dengan pendekatan ini, SVM mampu menghasilkan model klasifikasi yang kuat, terutama dalam kasus dengan dimensi data tinggi dan distribusi kelas yang kompleks (Anggoro & Novitaningrum, 2021). *Light*

Gradient Boosting Machine (LightGBM) adalah algoritma *gradient boosting* berbasis pohon keputusan yang dirancang untuk efisiensi dan skalabilitas tinggi. Keunggulan utama LightGBM antara lain kecepatan pelatihan yang lebih cepat, penggunaan memori yang lebih efisien, akurasi yang lebih baik, dan kemampuannya dalam menangani data dalam skala besar (Yang *et al.*, 2023).

Perbedaan utama LightGBM dengan algoritma *boosting* lainnya terletak pada metode pertumbuhan pohon keputusan, yang dilakukan secara *leaf-wise* (vertikal), bukan *level-wise* (horizontal). Pendekatan *leaf-wise* ini memungkinkan pengurangan *loss* yang lebih besar pada setiap iterasi, yang pada akhirnya menghasilkan model dengan kinerja prediktif yang lebih tinggi (Noviandy *et al.*, 2024). Klasifikasi adalah proses untuk mengelompokkan data berdasarkan fitur tertentu (Asri Mulyani *et al.*, 2025), dalam hal ini digunakan untuk mendeteksi penyakit jantung melalui data tabular berformat .csv. *Machine learning* adalah cabang dari kecerdasan buatan (AI) dan ilmu komputer yang berfokus pada pengembangan sistem yang dapat belajar secara otomatis dari data (Sharma & Chaudhary, 2023). Tujuan utama dari *machine learning* adalah memungkinkan komputer untuk meningkatkan kinerjanya secara bertahap tanpa perlu diprogram ulang secara eksplisit oleh manusia, dengan meniru pola pembelajaran yang dilakukan oleh manusia (Manirho *et al.*, 2020).

2. Metodologi Penelitian

Penelitian ini mengadopsi pendekatan *machine learning* untuk klasifikasi penyakit jantung secara efisien. Algoritma *machine learning* digunakan untuk mempelajari dan mengidentifikasi pola dari atribut pasien, seperti usia, jenis kelamin, tekanan darah, dan kadar kolesterol, dengan tujuan untuk membedakan antara pasien yang sehat dan yang menderita penyakit jantung. Implementasi model dilakukan menggunakan bahasa pemrograman *Python*. Dataset yang digunakan dalam penelitian ini berasal dari *UCI Heart Disease* dan mencakup 920 catatan medis pasien. Tahapan penelitian meliputi pengambilan data, pra-pemrosesan, pembagian dataset, penskalaan fitur, pelatihan model, dan evaluasi kinerja.

Pengambilan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari platform Kaggle, yang mengintegrasikan berbagai subset data dari *UCI Machine Learning Repository*. Dataset ini terdiri atas 920 entri pasien dengan 16 atribut yang merepresentasikan parameter klinis yang relevan untuk diagnosis penyakit jantung. Setiap entri dalam dataset menggambarkan satu pasien dengan fitur-fitur seperti *age* (usia), *sex* (jenis kelamin), *cp* (tipe nyeri dada), *trestbps* (tekanan darah istirahat), *chol* (kadar kolesterol), *fbs* (kadar gula darah puasa), *restecg* (hasil elektrokardiogram), *thalch* (detak jantung maksimal), *exang* (kerusakan eksersais), *oldpeak* (depresi segmen ST), *slope* (kemiringan segmen ST), *ca* (jumlah pembuluh darah utama yang tersumbat), dan *thal* (kelainan darah).

id	age	sex	dataset	cp	trestbps	chol	fbs	restecg	thalch	exang	oldpeak	slope	ca	thal	num
1	63	Male	Cleveland typical ang	145	233	TRUE	lv hypertn	150	FALSE	2.3	downslop	0	fixed defe	0	
2	67	Male	Cleveland asympt	160	286	FALSE	lv hypertn	108	TRUE	1.5	flat	3	normal	2	
3	67	Male	Cleveland asympt	120	229	FALSE	lv hypertn	129	TRUE	2.6	flat	2	reversible	1	
4	37	Male	Cleveland non-angin	130	250	FALSE	normal	187	FALSE	3.5	downslop	0	normal	0	
5	41	Female	Cleveland atypical ar	130	204	FALSE	lv hypertn	172	FALSE	1.4	upsloping	0	normal	0	
6	56	Male	Cleveland atypical ar	120	236	FALSE	normal	178	FALSE	0.8	upsloping	0	normal	0	
7	62	Female	Cleveland atypical	140	268	FALSE	lv hypertn	160	FALSE	3.6	downslop	2	normal	3	
8	57	Female	Cleveland asympt	120	354	FALSE	normal	163	TRUE	0.6	upsloping	0	normal	0	
9	63	Male	Cleveland asympt	130	254	FALSE	lv hypertn	147	FALSE	1.4	flat	1	reversible	2	
10	53	Male	Cleveland asympt	140	203	TRUE	lv hypertn	155	TRUE	3.1	downslop	0	reversible	1	
11	57	Male	Cleveland asympt	140	192	FALSE	normal	148	FALSE	0.4	flat	0	fixed defe	0	
12	56	Female	Cleveland atypical ar	140	294	FALSE	lv hypertn	153	FALSE	1.3	flat	0	normal	0	
13	56	Male	Cleveland atypical ar	130	256	TRUE	lv hypertn	142	TRUE	0.6	flat	1	fixed defe	2	
14	44	Male	Cleveland atypical ar	120	263	FALSE	normal	173	FALSE	0	upsloping	0	reversible	0	
15	52	Male	Cleveland non-angin	172	199	TRUE	normal	162	FALSE	0.5	upsloping	0	reversible	0	
16	57	Male	Cleveland non-angin	150	168	FALSE	normal	174	FALSE	1.6	upsloping	0	normal	0	
17	48	Male	Cleveland atypical ar	110	229	FALSE	normal	168	FALSE	1	downslop	0	reversible	1	
18	54	Male	Cleveland asympt	140	239	FALSE	normal	160	FALSE	1.2	upsloping	0	normal	0	

Gambar 1. Dataset

Pre-Processing

Tahap pra-pemrosesan bertujuan untuk memastikan kualitas data yang optimal sebelum digunakan dalam pelatihan model (Côté *et al.*, 2024). Langkah pertama

melibatkan transformasi variabel target, di mana kolom *num* dikonversi menjadi format biner: nilai 0 menunjukkan "Tidak Sakit", sementara nilai lebih dari 0 dikategorikan sebagai "Sakit" (1). Selanjutnya, penanganan terhadap data hilang (*missing values*) dilakukan. Untuk fitur numerik seperti *trestbps* dan *chol*, nilai yang hilang diimputasi menggunakan rata-rata kolom. Sementara itu, untuk fitur kategorikal, data hilang diatasi dengan mengganti nilai tersebut dengan modus atau label "*Unknown*". Seluruh fitur kategorikal, seperti *sex*, *cp*, dan *thal*, kemudian dikonversi ke dalam bentuk numerik menggunakan teknik *One-Hot Encoding*, agar kompatibel dengan algoritma *machine learning* yang tidak dapat memproses nilai non-numerik.

Pembagian Dataset

Setelah tahap pembersihan data, dataset dibagi menjadi dua bagian: 80% digunakan sebagai data latih dan 20% sebagai data uji. Pembagian dilakukan secara stratifikasi berdasarkan kelas target untuk memastikan distribusi kelas yang seimbang antara data latih dan data uji. Untuk meningkatkan generalisasi model, penelitian ini menggunakan teknik validasi silang (*cross-validation*) dengan metode *k-fold* (misalnya *k*=5 atau *k*=10), sehingga setiap subset data digunakan secara bergantian sebagai data uji. Nilai akhir adalah rata-rata dari seluruh iterasi, yang memberikan estimasi kinerja model yang lebih stabil dan minim bias.

Penskalaan Fitur

Fitur numerik pada data latih dan uji dinormalisasi menggunakan metode *StandardScaler*. Proses ini dilakukan untuk menyamakan skala nilai antar fitur, yang sangat penting bagi algoritma yang sensitif terhadap skala, seperti SVM.

Pembangunan dan Pelatihan Model

Penelitian ini menerapkan dua algoritma klasifikasi, yaitu *Support Vector Machine* (SVM) dan *Light Gradient Boosting Machine* (LightGBM). SVM berfungsi dengan mencari *hyperplane* optimal untuk memisahkan kelas data, sementara LightGBM adalah algoritma *gradient boosting* yang efisien dan unggul dalam performa. Kedua model ini dilatih menggunakan data latih (*X_train_final* dan *y_train*) yang telah diproses melalui serangkaian tahapan pra-pemrosesan, termasuk transformasi target, imputasi data hilang, dan *encoding*

fitur kategorikal. Pemilihan parameter untuk masing-masing model dilakukan berdasarkan kombinasi *tuning* empiris dan rekomendasi literatur untuk mendapatkan performa optimal dalam tugas klasifikasi (Bischl *et al.*, 2023). Untuk SVM, parameter utama yang dipertimbangkan adalah C (*regularization parameter*) dan kernel (misalnya, *rbf* atau *linear*). Nilai C yang lebih tinggi akan mengurangi margin dan meningkatkan akurasi pelatihan, sementara kernel *rbf* seringkali lebih efektif untuk data yang tidak dapat dipisahkan secara linear.

Pemilihan kernel *rbf* dan nilai C tertentu dilakukan setelah eksperimen awal menunjukkan konfigurasi ini memberikan keseimbangan terbaik antara bias dan varians, serta performa recall yang tinggi pada kelas positif. Untuk LightGBM, parameter seperti *n_estimators* (jumlah pohon), *learning_rate* (ukuran langkah), dan *num_leaves* (jumlah daun maksimum per pohon) menjadi fokus. *N_estimators* yang lebih tinggi dapat meningkatkan akurasi namun berisiko overfitting, sementara *learning_rate* mengontrol kontribusi setiap pohon dan *num_leaves* memengaruhi kompleksitas model. Konfigurasi awal (misalnya, *n_estimators* = 100, *learning_rate* = 0.1, *num_leaves* = 31) dipilih sebagai titik awal yang seimbang dan dapat disesuaikan lebih lanjut melalui *hyperparameter tuning* untuk mengoptimalkan kinerja model pada dataset spesifik ini. Pemilihan algoritma ini bertujuan untuk mengevaluasi kinerja klasifikasi secara komparatif, baik dari segi akurasi maupun kemampuan dalam mendeteksi kasus positif penyakit jantung.

Evaluasi Model

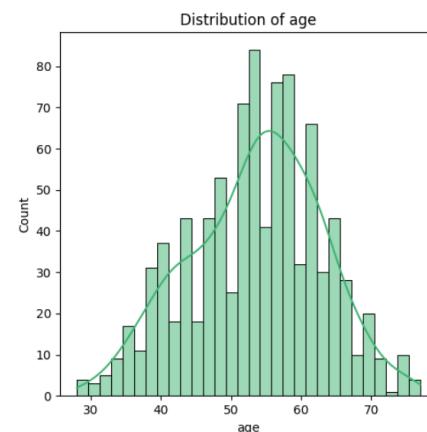
Evaluasi model dilakukan menggunakan data uji dengan metrik seperti *confusion matrix*, akurasi, presisi, recall, dan *F1-score*. *Confusion matrix* digunakan untuk memeriksa distribusi prediksi benar dan salah, sedangkan akurasi mengukur ketepatan keseluruhan prediksi. Presisi mengukur ketepatan prediksi positif, dan recall menjadi metrik penting dalam konteks medis karena menunjukkan kemampuan model dalam mendeteksi seluruh kasus positif. *F1-score* digunakan untuk menyeimbangkan antara presisi dan recall.

3. Hasil dan Pembahasan

Hasil

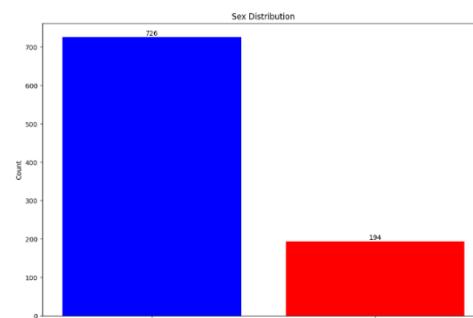
Hasil Dataset

Berdasarkan hasil visualisasi pada *Gambar 2*, distribusi usia pasien menunjukkan bahwa kelompok usia 50-60 tahun memiliki jumlah pasien terbanyak, yang merupakan rentang usia yang rentan terhadap penyakit jantung.



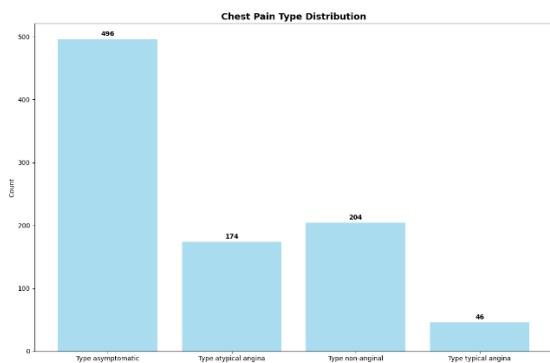
Gambar 2. Hasil Distribusi Usia

Dari segi demografis pada *Gambar 3*, didominasi oleh pasien berjenis kelamin pria sebanyak 726 orang dibandingkan wanita sebanyak 194 orang.



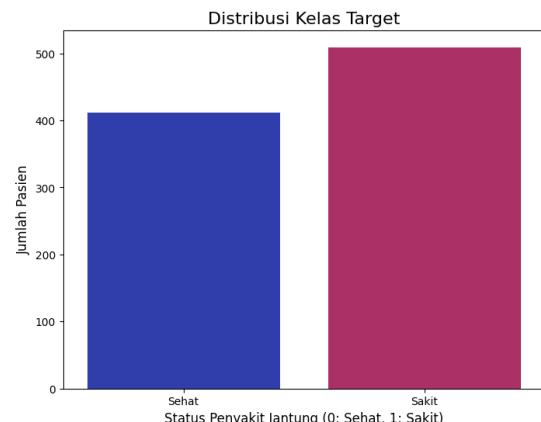
Gambar 3. Hasil Distribusi Jenis Kelamin

Pada *Gambar 4* fitur klinis utama, tipe nyeri dada yang paling banyak tercatat adalah '*Asymptomatic*', yang mengindikasikan bahwa banyak kasus penyakit jantung tidak menunjukkan gejala nyeri dada yang khas.



Gambar 4. Distribusi Tipe Nyeri Dada

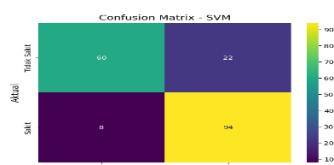
Distribusi kelas target (pasien dengan dan tanpa penyakit jantung) sangat penting untuk memahami keseimbangan data.



Gambar 5. Distribusi Target

Tabel 2. Metrik Evaluasi

Model	Kelas	Precision	Recall	F1-Score	Support
SVM	0 (Tidak Sakit)	0.88	0.73	0.8	82
SVM	1 (Sakit)	0.81	0.92	0.86	102
SVM	Accuracy			0.84	184
SVM	Macro Avg	0.85	0.83	0.83	184
SVM	Weighted Avg	0.84	0.84	0.83	184
LightGBM	0 (Tidak Sakit)	0.83	0.78	0.81	82
LightGBM	1 (Sakit)	0.83	0.87	0.85	102
LightGBM	Accuracy			0.83	184
LightGBM	Macro Avg	0.83	0.83	0.83	184
LightGBM	Weighted Avg	0.83	0.83	0.83	184



Gambar 6. Confusion Matrix SVM

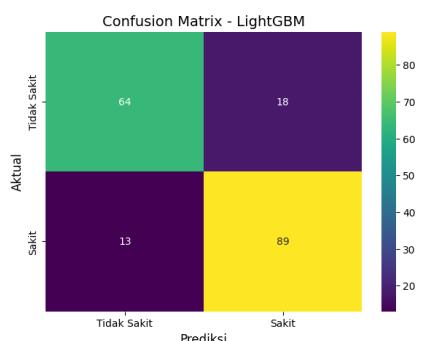
Pada Gambar 5 menunjukkan bahwa terdapat 510 pasien yang terdiagnosis menderita penyakit jantung (kelas 1) dan 410 pasien yang tidak terdiagnosis (kelas 0). Komposisi ini menunjukkan bahwa dataset relatif seimbang, sehingga dapat mengurangi potensi bias pada model klasifikasi.

Hasil Kinerja Model Klasifikasi

Berdasarkan hasil evaluasi pada Tabel 2, kedua model menunjukkan kemampuan yang baik dalam mengklasifikasikan penyakit jantung dengan akurasi di atas 83%. Model SVM menunjukkan keunggulan tipis dalam hal akurasi keseluruhan. Namun, dalam diagnosis medis, metrik *recall* untuk kelas 'Sakit' (kelas 1) menjadi sangat krusial. *Recall* mengukur kemampuan model untuk mengidentifikasi semua pasien yang benar-benar menderita penyakit jantung. Model SVM memiliki nilai *recall* sebesar 92%, lebih tinggi dibandingkan model lainnya. Ini berarti model tersebut lebih andal dalam meminimalkan kasus *False Negative*, yaitu kondisi di mana pasien yang sakit salah didiagnosis sebagai sehat. Kegagalan mendeteksi penyakit (*False Negative*) memiliki risiko yang jauh lebih besar daripada kesalahan diagnosis pada pasien sehat (*False Positive*).

Berdasarkan hasil *confusion matrix* pada Gambar 6, model SVM menunjukkan performa yang baik dalam mendeteksi pasien dengan penyakit jantung. Pada model SVM, sebanyak 94 pasien sakit berhasil diklasifikasikan dengan benar sebagai *True Positive*.

(TP), sementara 60 pasien sehat juga berhasil dikenali dengan tepat sebagai *True Negative* (TN). Namun, model ini masih melakukan 22 kesalahan *False Positive* (FP), yaitu kasus ketika pasien sehat diprediksi sebagai sakit, serta 8 kesalahan *False Negative* (FN), yakni pasien sakit yang salah diklasifikasikan sebagai sehat. Analisis distribusi error pada SVM menunjukkan bahwa model ini cenderung lebih konservatif dalam memprediksi "sakit" (hanya 8 FN), yang sangat diinginkan dalam diagnosis medis untuk menghindari risiko terlewatnya kasus positif.



Gambar 7. Confusion Matrix LightGBM

Sementara pada Gambar 7, model LightGBM menghasilkan 89 *True Positive* dan 64 *True Negative*, dengan jumlah kesalahan *False Positive* sebanyak 18 dan *False Negative* sebanyak 13. Dibandingkan SVM, LightGBM memiliki jumlah *False Negative* yang lebih tinggi (13 FN), meskipun memiliki *False Positive* yang sedikit lebih rendah (18 FP). Hal ini mengindikasikan bahwa LightGBM, meskipun akurat secara keseluruhan, sedikit kurang sensitif dalam mengidentifikasi semua kasus positif penyakit jantung dibandingkan SVM.

Tabel 3. Metrik Hasil Evaluasi

Metrik	SVM	LightGBM
Accuracy	0.84	0.83
Recall (Kelas 1/Sakit)	0.92	0.87
F1-Score (Kelas 1/Sakit)	0.86	0.85
Macro Avg F1-Score	0.83	0.83

Berdasarkan hasil evaluasi pada tabel 3, algoritma *Support Vector Machine* (SVM) menunjukkan performa yang lebih unggul dibandingkan LightGBM dalam beberapa metrik penting. SVM mencatat akurasi sebesar 84%, sedikit lebih tinggi dibandingkan LightGBM yang mencapai 83%, mengindikasikan

kemampuan prediksi umum yang lebih baik. Keunggulan paling signifikan terlihat pada metrik *recall* untuk kelas 1 (sakit), di mana SVM mencapai nilai 0.92, lebih tinggi dibandingkan LightGBM yang hanya mencapai 0.87. Hal ini sangat penting dalam konteks medis karena menunjukkan bahwa SVM lebih sensitif dalam mendeteksi pasien yang benar-benar sakit, serta lebih efektif dalam meminimalkan kesalahan *false negative*. Pada metrik F1-score untuk kelas 1, SVM kembali unggul dengan nilai 0.86, dibandingkan 0.85 pada LightGBM, menunjukkan konsistensi dalam ketepatan dan kelengkapan deteksi kasus positif. Meskipun pada *macro average F1-score* kedua model mencatat nilai yang sama sebesar 0.83, keunggulan SVM pada kelas yang lebih kritis menjadikannya pilihan yang lebih tepat. Dengan demikian, dapat disimpulkan bahwa SVM merupakan algoritma yang paling unggul dan direkomendasikan untuk digunakan dalam klasifikasi penyakit jantung. Untuk pengembangan di masa depan, penelitian ini dapat diperluas dengan beberapa pendekatan. Pertama, penggunaan dataset yang lebih besar dan beragam, atau bahkan data klinis nyata dari rumah sakit, dapat meningkatkan generalisasi dan keandalan model. Hal ini akan memungkinkan model untuk belajar dari variasi kasus yang lebih luas dan mencerminkan kondisi populasi yang sebenarnya. Kedua, penerapan teknik optimasi parameter (*hyperparameter tuning*) yang lebih canggih, seperti *Grid Search*, *Random Search*, atau optimasi *Bayesian*, dapat digunakan untuk menemukan kombinasi parameter optimal yang memaksimalkan kinerja model secara sistematis. Ini akan membantu mengidentifikasi konfigurasi model terbaik yang mungkin tidak ditemukan melalui tuning empiris. Ketiga, potensi integrasi model klasifikasi ini ke dalam sistem klinis nyata, seperti sistem pendukung keputusan dokter, perlu dieksplorasi. Integrasi ini akan memerlukan validasi ekstensif di lingkungan klinis, pertimbangan etika, dan pengembangan antarmuka yang ramah pengguna untuk memfasilitasi diagnosis dini dan pengambilan keputusan medis yang lebih baik.

Pembahasan

Penyakit jantung koroner (PJK) menjadi penyebab utama kematian di dunia, sehingga deteksi dini sangat diperlukan untuk mengurangi angka kematian akibat komplikasi lebih lanjut. Dalam upaya mendukung diagnosis yang lebih akurat, penelitian ini

membandingkan kinerja dua algoritma *machine learning*, yaitu *Support Vector Machine (SVM)* dan *Light Gradient Boosting Machine (LightGBM)*. Hasil dari penelitian ini menunjukkan bahwa meskipun kedua algoritma mampu mengklasifikasikan penyakit jantung dengan baik, *SVM* menunjukkan kinerja yang lebih unggul pada beberapa metrik yang sangat penting dalam diagnosis medis. Penelitian sebelumnya, seperti yang dilakukan oleh Ahmad dan Polat (2023), telah membuktikan bahwa *SVM* dapat digunakan untuk memprediksi penyakit jantung dengan akurasi tinggi. Namun, hal yang sering terlewat adalah fokus pada *recall*, yang mengukur kemampuan model dalam mendeteksi pasien dengan penyakit. *SVM* dalam penelitian ini mencatatkan *recall* sebesar 92%, yang berarti lebih efektif dalam mendeteksi pasien yang benar-benar sakit dibandingkan dengan *LightGBM* yang hanya memperoleh 87%. *Recall* yang tinggi ini sangat penting dalam dunia medis, karena kegagalan mendeteksi pasien sakit atau *false negative* dapat berisiko sangat besar bagi pasien. Hasil ini sejalan dengan penelitian Anggoro dan Novitaningrum (2021) yang menunjukkan bahwa *SVM* lebih efektif dalam mengidentifikasi kasus-kasus penting, seperti pada penyakit jantung. Meskipun *LightGBM* memiliki akurasi 83% dan *F1-score* 85%, algoritma ini masih mencatatkan lebih banyak *false negatives* (13 FN) dibandingkan dengan *SVM* (8 FN). *SVM* lebih baik dalam mengurangi kesalahan deteksi kasus positif, yang merupakan aspek yang sangat krusial dalam sistem medis untuk meminimalkan risiko pasien yang salah didiagnosis sehat.

Dalam hal ini, meskipun *LightGBM* memberikan hasil yang solid, algoritma ini sedikit lebih lambat dalam mengidentifikasi seluruh kasus positif penyakit jantung, sebagaimana terlihat dari *false negative* yang lebih tinggi. Keunggulan *SVM* dalam *recall* dan *F1-score* menunjukkan bahwa algoritma ini lebih andal dalam mendeteksi kasus-kasus kritis penyakit jantung yang memerlukan penanganan cepat. Seperti yang ditunjukkan oleh Baldomero-Naranjo *et al.* (2021), *SVM* sangat efektif dalam menghadapi dataset dengan distribusi yang tidak seimbang, yang sering terjadi dalam penyakit jantung. Penelitian ini sejalan dengan temuan Asif *et al.* (2023) yang menyarankan agar pemilihan algoritma *machine learning* tidak hanya mengandalkan akurasi, melainkan juga

mempertimbangkan *recall* yang dapat mengurangi risiko kesalahan diagnosis pada pasien yang membutuhkan perawatan segera. *SVM* berhasil menunjukkan keunggulannya dalam aspek ini, yang membuatnya lebih direkomendasikan untuk diterapkan dalam sistem deteksi dini penyakit jantung. Walaupun *LightGBM* lebih cepat dalam proses pelatihan dan memiliki beberapa keunggulan dalam hal efisiensi memori, hasil ini menunjukkan bahwa *SVM* lebih unggul dalam hal keandalan dalam diagnosis medis. Hal ini juga sesuai dengan Azzahra' (2024) yang menjelaskan bahwa deteksi penyakit jantung yang tepat sangat bergantung pada *recall* yang tinggi untuk meminimalkan kesalahan diagnosis yang berbahaya. Ke depan, untuk meningkatkan *generalizability* model, disarankan untuk memperluas penelitian ini dengan menggunakan *dataset* yang lebih besar dan lebih beragam, serta memvalidasi model dengan data klinis nyata dari rumah sakit. Bischl *et al.* (2023) juga menyarankan penggunaan teknik *optimasi hyperparameter* yang lebih canggih untuk meningkatkan performa model, seperti menggunakan *Grid Search* atau *Random Search*. Selain itu, penelitian lebih lanjut dapat memfokuskan pada integrasi model *SVM* ke dalam *sistem pendukung keputusan medis*, untuk mendukung pengambilan keputusan yang lebih cepat dan lebih akurat. Dengan mempertimbangkan hasil yang lebih baik dari *SVM* dalam hal sensitivitas terhadap kasus positif, penelitian ini menyimpulkan bahwa *SVM* merupakan algoritma yang lebih tepat untuk digunakan dalam *deteksi dini penyakit jantung*. Penelitian ini memberikan gambaran lebih jelas tentang pilihan algoritma yang lebih efisien dalam mengidentifikasi kasus kritis dan dapat diterapkan dalam praktik medis untuk meningkatkan kualitas diagnosis.

4. Kesimpulan dan Saran

Penelitian ini telah melakukan perbandingan kinerja dua algoritma *machine learning*, yaitu *Support Vector Machine (SVM)* dan *Light Gradient Boosting Machine (LightGBM)*, dalam tugas klasifikasi penyakit jantung. Berdasarkan hasil pengujian, kedua algoritma menunjukkan performa yang baik, namun *SVM* unggul dalam beberapa aspek yang sangat penting untuk diagnosis medis. *SVM* mencapai akurasi tertinggi sebesar 84%, *F1-score* 86%, dan *recall* 92%,

yang menandakan kemampuan model dalam mendeteksi kasus positif secara lebih akurat dan andal. Sementara itu, *LightGBM* menunjukkan kinerja yang solid dengan akurasi 83% dan *F1-score* 85%, namun sedikit kurang sensitif dalam mendeteksi kasus positif jika dibandingkan dengan *SVM*. Berdasarkan hasil ini, *SVM* lebih direkomendasikan untuk diterapkan dalam sistem deteksi dini penyakit jantung, mengingat sensitivitasnya yang lebih tinggi terhadap pasien dengan kondisi positif. Penelitian ini memberikan gambaran yang lebih jelas tentang pemilihan model klasifikasi berbasis data medis yang lebih efektif, serta menekankan pentingnya akurasi dalam diagnosis penyakit jantung, yang sangat bergantung pada kemampuan model untuk meminimalkan *false negative*. Namun, penelitian ini memiliki keterbatasan, di antaranya penggunaan satu sumber dataset (UCI) dan tidak dilakukannya optimasi *hyperparameter* secara menyeluruh. Untuk penelitian mendatang, disarankan untuk melakukan validasi model menggunakan data klinis nyata dari rumah sakit lokal, guna menguji *generalisasi* model pada populasi yang lebih beragam. Selain itu, eksplorasi lebih lanjut pada teknik *feature engineering* yang lebih canggih, serta optimasi *hyperparameter*, dapat menjadi fokus utama untuk meningkatkan akurasi dan reliabilitas model klasifikasi di masa depan.

5. Daftar Pustaka

- Ahmad, A. A., & Polat, H. (2023). Prediction of heart disease based on machine learning using jellyfish optimization algorithm. *Diagnostics*, 13(14), 2392.
- Anggoro, D. A., & Novitaningrum, D. (2021). Comparison of accuracy level of support vector machine (SVM) and artificial neural network (ANN) algorithms in predicting diabetes mellitus disease. *ICIC Express Letters*, 15(1), 9-18.
- Asmianto, Pusawidjayanti, K., Hafizh, M., & Supeno, I. (2022, November). Comparative of classification algorithm: Decision tree, SVM, and KNN for heart diseases prediction. In *AIP Conference Proceedings* (Vol. 2639, No. 1, p. 030005). AIP Publishing LLC. <https://doi.org/10.1063/5.0110243>.
- Asri Mulyani, Sarah Khoerunisa, & Dede Kurniadi. (2025). Perbandingan kinerja algoritma KNN dan SVM menggunakan SMOTE untuk klasifikasi penyakit diabetes. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 14(1), 25–34. <https://doi.org/10.22146/jnteti.v14i1.15198>.
- Azzahra', L. (2024). Hospital-based coronary heart disease prevention and control efforts: A literature review. *Jurnal Medika Usada*, 7(2), 46–51. <https://doi.org/10.54107/medikausada.v7i2.305>.
- Baldomero-Naranjo, M., Martínez-Merino, L. I., & Rodríguez-Chía, A. M. (2021). A robust SVM-based approach with feature selection and outliers detection for classification problems. *Expert Systems with Applications*, 178, 115017. <https://doi.org/10.1016/j.eswa.2021.115017>.
- Bischl, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., ... & Lindauer, M. (2023). Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13(2), e1484. <https://doi.org/10.1002/widm.1484>.
- Côté, P. O., Nikanjam, A., Ahmed, N., Humeniuk, D., & Khomh, F. (2024). Data cleaning and machine learning: a systematic literature review. *Automated Software Engineering*, 31(2), 54.
- Dian, J., Silalahi, F. D., & Setiawan, N. D. (2021). *A Heartbeat Monitoring System To Detect Internet Of Things-Based Heart Health Levels Using Android*. *JUPITER (Jurnal Penelitian Ilmu Dan Teknologi Komputer)*, 13 (2), 69–75.
- Erawati, A. D. (2021). Peningkatan Pengetahuan tentang Penyakit Jantung Koroner. *Jurnal ABDIMAS-HIP Pengabdian Kepada Masyarakat*, 2(1), 6-9.

- Khan Mamun, M. M. R., & Elfouly, T. (2023). Detection of cardiovascular disease from clinical parameters using a one-dimensional convolutional neural network. *Bioengineering*, 10(7), 796. <https://doi.org/10.3390/bioengineering10070796>.
- Maniraho, P., Mahoro, L. J., Niyigaba, E., Bizimana, Z., & Ahmad, T. (2020). Detecting intrusions in computer network traffic with machine learning approaches. *International Journal of Intelligent Engineering and Systems*, 13(3), 433-445.
- Noviandy, T. R., Idroes, G. M., Maulana, A., Afidh, R. P. F., & Idroes, R. (2024). Optimizing hepatitis C virus inhibitor identification with LightGBM and tree-structured parzen estimator sampling. *Engineering, Technology & Applied Science Research*, 14(6), 18810-18817. <https://doi.org/10.48084/etasr.8947>.
- Nurrokhman, M. M. Z. (2023). Perbandingan Algoritma Support Vector Machine dan Neural Network untuk Klasifikasi Penyakit Hati. *The Indonesian Journal of Computer Science*, 12(4). <https://doi.org/10.33022/ijcs.v12i4.3274>.
- Pratama, R., Siregar, A. M., Lestari, S. A. P., & Faisal, S. (2024). Implementation of diabetes prediction model using random forest algorithm, K-Nearest Neighbor, and logistic regression. *Jurnal Teknik Informatika (Jutif)*, 5(4), 1165–1174. <https://doi.org/10.52436/1.jutif.2024.5.4.2593>.
- Sepharni, A., Hendrawan, I. E., & Rozikin, C. (2022). Klasifikasi penyakit jantung dengan menggunakan algoritma C4.5. *STRING (Satuan Tulisan Riset Dan Inovasi Teknologi)*, 7(2), 117. <https://doi.org/10.30998/string.v7i2.12012>.
- Sharma, S., & Chaudhary, P. (2023). *Machine learning and deep learning. Quantum Computing and Artificial Intelligence: Training Machine and Deep Learning Algorithms on Quantum Computers*, 71–84. <https://doi.org/10.1515/9783110791402-004>.
- Tampubolon, L. F., Ginting, A., & Saragi Turnip, F. E. (2023). Gambaran faktor yang mempengaruhi kejadian penyakit jantung koroner (PJK) di Pusat Jantung Terpadu (PJT). *Jurnal Ilmiah Permas: Jurnal Ilmiah STIKES Kendal*, 13(3), 1043–1052. <https://doi.org/10.32583/pskm.v13i3.1077>.
- Yang, H., Chen, Z., Yang, H., & Tian, M. (2023). Predicting coronary heart disease using an improved *LightGBM* model: Performance analysis and comparison. *IEEE Access*, 11(February), 23366–23380. <https://doi.org/10.1109/ACCESS.2023.3253885>.
- Yi, J., Yu, P., Huang, T., & Xu, Z. (2024). Optimization of transformer heart disease prediction model based on particle swarm optimization algorithm. 2024 6th International Conference on Frontier Technologies of Information and Computer, ICFTIC 2024, 1109–1113. <https://doi.org/10.1109/ICFTIC64248.2024.10913096>.