

Penerapan Model Machine Learning untuk Memprediksi Serangan Jantung Dini

Green Ferry Mandias^{1*}, Ivanna Junamel Manoppo²

Fakultas Ilmu Komputer Universitas Klabat¹,

Fakultas Keperawatan Universitas Klabat²

Jl. A. Mononutu, Airmadidi, Minahasa Utara, SULUT, Indonesia

Sur-el : green@unklab.ac.id^{1*}, i.manoppo@unklab.ac.id²

^{*)} Corresponden Author

Received: 26 September 2025 Reviewed: 02 October 2025 Accepted: 27 October 2025

Abstract : Heart disease is one of the leading causes of death worldwide, and early detection is crucial in reducing mortality rates. In Indonesia, heart disease is a primary cause of death, exacerbated by limited access to healthcare, especially in rural areas. Traditional diagnostic methods, such as physical examinations and EKG, often lack accuracy in predicting heart attacks. This research aims to develop an early prediction model for heart attacks using machine learning, specifically Random Forest and Support Vector Machine (SVM). These models were trained using a dataset containing various medical variables, including age, gender, blood pressure, cholesterol levels, and ECG results. The study finds that the Random Forest model outperforms SVM, with an accuracy of 90% and a recall of 93% for heart disease detection, making it more reliable for early detection of at-risk patients. The results suggest that machine learning can significantly enhance early heart attack detection, offering a potential solution to reduce heart disease-related mortality.

Keyword : Machine Learning, Early Detection, Heart Disease

Abstrak : Penyakit jantung merupakan salah satu penyebab utama kematian di dunia, dan deteksi dini sangat penting untuk mengurangi angka kematian. Di Indonesia, penyakit jantung juga menjadi penyebab utama kematian, yang diperburuk oleh keterbatasan akses ke fasilitas kesehatan, terutama di daerah terpencil. Metode diagnostik tradisional, seperti pemeriksaan fisik dan EKG, sering kali tidak cukup akurat dalam memprediksi serangan jantung. Penelitian ini bertujuan untuk mengembangkan model prediksi dini serangan jantung menggunakan machine learning, khususnya model Random Forest dan Support Vector Machine (SVM). Model-model ini dilatih menggunakan dataset yang mencakup berbagai variabel medis, seperti usia, jenis kelamin, tekanan darah, kadar kolesterol, dan hasil EKG. Hasil penelitian menunjukkan bahwa model Random Forest memiliki kinerja yang lebih baik dibandingkan SVM, dengan akurasi 90% dan recall 93% dalam mendeteksi penyakit jantung, menjadikannya lebih andal untuk deteksi dini pasien berisiko. Hasil ini menunjukkan bahwa machine learning dapat secara signifikan meningkatkan deteksi dini serangan jantung, yang merupakan solusi potensial untuk mengurangi angka kematian akibat penyakit jantung.

Kata Kunci : Pembelajaran Mesin, Deteksi Dini, Penyakit Jantung

1. PENDAHULUAN

Penyakit jantung menjadi salah satu penyebab kematian utama di dunia, dengan statistik yang menunjukkan peningkatan jumlah penderita serangan jantung setiap tahunnya [1] [2]

[3]. Menurut Organisasi Kesehatan Dunia (WHO), penyakit kardiovaskular menyumbang sekitar 31% dari total kematian global, dengan serangan jantung akut sebagai salah satu penyebab terbesar [4] [5]. Meskipun ada upaya pencegahan dan pengobatan, serangan jantung tetap menjadi

masalah kesehatan global yang memerlukan perhatian serius. Salah satu tantangan terbesar dalam mengatasi masalah ini adalah kemampuan untuk mendeteksi serangan jantung secara dini, yang sangat penting dalam mengurangi angka kematian akibat kondisi ini [6].

Di Indonesia, penyakit jantung juga menjadi penyebab utama kematian, dengan prevalensi yang terus meningkat. Data dari Kementerian Kesehatan Republik Indonesia menunjukkan bahwa penyakit jantung menyumbang lebih dari 20% dari total kematian di negara ini [7] [8]. Meskipun terdapat sejumlah rumah sakit dan fasilitas kesehatan yang dilengkapi dengan alat-alat diagnostik modern, deteksi dini terhadap serangan jantung masih terbatas di banyak daerah, terutama di wilayah terpencil. Kendala utama yang dihadapi adalah kurangnya tenaga medis terlatih, keterbatasan alat diagnostik yang canggih, serta terbatasnya akses masyarakat terhadap fasilitas kesehatan yang memadai, yang mengakibatkan terlambatnya penanganan pada kasus serangan jantung [9].

Deteksi dini sangat penting untuk menurunkan angka kematian akibat serangan jantung. Banyaknya kasus serangan jantung yang tidak terdeteksi sebelumnya disebabkan oleh keterbatasan metode diagnosis tradisional, yang umumnya bergantung pada pemeriksaan fisik, tes darah, dan EKG [10]. Meskipun metode ini cukup efektif, namun sering kali tidak memberikan gambaran yang cukup akurat mengenai kemungkinan terjadinya serangan jantung. Oleh karena itu, penting untuk memiliki sistem yang memungkinkan pengambilan keputusan medis

yang cepat dan akurat, agar pasien dapat segera mendapat penanganan yang sesuai sebelum terlambat [11] [12].

Kemajuan teknologi dalam bidang kesehatan telah membawa perubahan signifikan dalam cara diagnosis dan pengobatan penyakit. Salah satu teknologi yang berkembang pesat adalah penggunaan *machine learning* dalam bidang medis [10]. *Machine learning* memiliki potensi besar untuk menganalisis data kesehatan dalam jumlah besar dan memberikan prediksi yang lebih akurat, termasuk dalam mendeteksi penyakit jantung secara dini [13]. Contoh penerapan sukses teknologi ini dapat dilihat pada prediksi penyakit diabetes dan kanker, di mana *machine learning* mampu meningkatkan akurasi diagnosis dan mempercepat waktu deteksi [14]. Dalam konteks penyakit jantung, *machine learning* dapat membantu menganalisis data medis pasien secara lebih komprehensif dan memberikan prediksi yang lebih tepat tentang kemungkinan terjadinya serangan jantung [15].

Meskipun banyak penelitian yang telah dilakukan untuk mengembangkan model prediksi serangan jantung dini, penerapan teknologi ini masih terbatas di beberapa institusi kesehatan. Salah satu masalah utama adalah validitas data medis yang sering kali tidak akurat atau tidak terintegrasi dengan baik antara berbagai sistem informasi kesehatan yang ada [8]. Hal ini menghambat pengembangan dan penerapan model prediksi yang lebih efektif. Oleh karena itu, penting untuk mengembangkan model prediksi serangan jantung yang dapat diterapkan secara luas

dan diintegrasikan dengan sistem kesehatan yang ada. Penelitian ini memilih metode machine learning karena keunggulannya dalam mengolah data medis yang besar dan kompleks untuk menghasilkan prediksi yang lebih akurat.

Penelitian ini bertujuan untuk mengembangkan model prediksi serangan jantung dini menggunakan *machine learning*, yang diharapkan dapat meningkatkan deteksi awal dan penanganan yang lebih cepat terhadap pasien berisiko. Kontribusi penelitian ini sangat relevan dalam dunia kesehatan, terutama dalam upaya mengurangi angka kematian akibat serangan jantung, dengan menyediakan alat prediksi yang lebih akurat dan efektif. Selain itu, penelitian ini juga dapat memberikan wawasan baru dalam penerapan teknologi *machine learning* dalam bidang medis, membuka peluang untuk pengembangan sistem kesehatan yang lebih canggih di masa depan.

2. METODE PENELITIAN

2.1. Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengembangkan dan menguji model machine learning dalam memprediksi serangan jantung dini. Model ini akan dilatih menggunakan data medis yang tersedia dan diukur efektivitasnya berdasarkan akurasi prediksi terhadap hasil diagnosa klinis.

a. Sumber Data

Sumber data yang digunakan dalam penelitian ini berasal dari dataset yang tersedia di *Kaggle*, yang berfokus pada prediksi penyakit jantung. Dataset ini mencakup berbagai variabel medis yang relevan, yang akan digunakan untuk melatih dan menguji model *machine learning* dalam memprediksi serangan jantung dini.

b. Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini berisi berbagai atribut medis yang penting untuk memprediksi risiko serangan jantung dini. Atribut-atribut tersebut adalah sebagai berikut:

- a) *Age*: Atribut numerik (integer) yang mewakili usia pasien dalam satuan tahun.
- b) *Sex*: Atribut kategorik (M/F) yang menunjukkan jenis kelamin pasien, dengan M untuk Laki-laki dan F untuk Perempuan.
- c) *ChestPainType*: Atribut kategorik (TA/ATA/NAP/ASY) yang menggambarkan jenis nyeri dada, yaitu TA untuk Angina Tipikal, ATA untuk Angina Atipikal, NAP untuk Nyeri Non-Anginal, dan ASY untuk Asimtomatik.
- d) *RestingBP*: Atribut numerik (mmHg) yang menunjukkan tekanan darah pasien saat dalam keadaan istirahat.
- e) *Cholesterol*: Atribut numerik (mg/dl) yang menggambarkan kadar kolesterol serum dalam darah pasien.
- f) *FastingBS*: Atribut biner (0/1) yang menunjukkan kadar gula darah puasa, di mana nilai 1 menunjukkan gula darah lebih dari 120

mg/dl, dan 0 menunjukkan tidak lebih dari 120 mg/dl.

- g) *RestingECG*: Atribut kategorik (Normal/ST/LVH) yang menggambarkan hasil elektrokardiogram saat istirahat, di mana "Normal" berarti tidak ada kelainan, "ST" menunjukkan kelainan gelombang ST-T, dan "LVH" menunjukkan Hipertrofi Ventrikel Kiri.
- h) *MaxHR*: Atribut numerik (dalam rentang 60–202) yang menunjukkan denyut jantung maksimum saat uji latihan.
- i) *ExerciseAngina*: Atribut biner (Y/N) yang menunjukkan apakah pasien mengalami angina (nyeri dada) saat aktivitas fisik. Y berarti "ya", dan N berarti "tidak".
- j) *Oldpeak*: Atribut numerik (desimal) yang menunjukkan depresi segmen ST akibat aktivitas, yang merupakan ukuran terkait tingkat stres pada jantung.
- k) *ST_Slope*: Atribut kategorik (Up/Flat/Down) yang menggambarkan kemiringan segmen ST saat latihan. Nilai ini bisa berupa upsloping, flat, atau downsloping.
- l) *HeartDisease*: Atribut biner (0/1) yang menunjukkan status penyakit jantung pasien, dengan nilai 1 menunjukkan terdiagnosis penyakit jantung, dan 0 menunjukkan tidak ada penyakit jantung.

Dataset ini memberikan berbagai informasi medis yang relevan, yang digunakan untuk melatih model *machine learning* guna memprediksi kemungkinan terjadinya serangan jantung.

2.2. Pemilihan Metode *Machine Learning*

Pemilihan model *machine learning* yang digunakan dalam penelitian ini didasarkan pada kajian literatur dan rekomendasi dari sumber yang telah dicatat oleh penulis sebelumnya. Metode klasifikasi seperti *Random Forest* dan *Support Vector Machine* (SVM) terbukti efektif dalam memprediksi serangan jantung dini dengan tingkat akurasi yang tinggi. Oleh karena itu, penelitian ini akan menggunakan kedua algoritma tersebut untuk membangun model prediksi. Pemilihan model ini juga dipengaruhi oleh kemampuannya dalam menangani data besar dan beragam variabel yang kompleks.

2.3. Prosedur Penelitian

Prosedur penelitian dilakukan secara bertahap, yang dijelaskan sebagai berikut:

- a. Pengumpulan Data: Data medis dikumpulkan dari rumah sakit dengan persetujuan etis yang sesuai. Data yang diperoleh mencakup informasi demografis, hasil pemeriksaan fisik, dan data tes medis yang relevan.
- b. Pra-pemrosesan Data: Data yang diperoleh kemudian dibersihkan dengan menghapus nilai yang hilang, menangani data yang tidak konsisten, dan melakukan normalisasi untuk memastikan bahwa variabel memiliki skala yang konsisten.
- c. Pembagian Data: Data dibagi menjadi dua set, yaitu set pelatihan (80% dari total data) dan set pengujian (20% dari total data). Pembagian ini dilakukan secara acak untuk menghindari bias dalam model.

- d. Pelatihan Model: Model *Random Forest* dan SVM akan dilatih menggunakan set pelatihan.
- e. Evaluasi Model: Model yang telah dilatih kemudian dievaluasi menggunakan set pengujian. Evaluasi dilakukan dengan menggunakan metrik akurasi, presisi, recall, dan F1-score untuk mengukur kinerja model dalam memprediksi serangan jantung dini.

2.4. Pengujian dan Validasi Model

Model yang telah dilatih akan diuji dengan menggunakan data yang tidak terlihat sebelumnya (set pengujian) untuk memastikan generalisasi model. Pengujian ini akan mencakup penghitungan beberapa metrik evaluasi, termasuk:

- a. Akurasi: Persentase prediksi yang benar dari total prediksi yang dilakukan oleh model.
- b. Presisi: Kemampuan model untuk mengklasifikasikan dengan benar kasus serangan jantung dini.
- c. Recall: Kemampuan model untuk mengidentifikasi semua kasus serangan jantung dini yang sebenarnya.
- d. F1-score: Harmonik dari presisi dan recall yang memberikan gambaran lebih komprehensif mengenai kinerja model.

Selain itu, *cross-validation* dengan teknik *k-fold* (misalnya $k=10$) akan digunakan untuk memastikan bahwa model tidak *overfitting* dan hasil evaluasi stabil.


2.5. Pengukuran Kinerja dan Evaluasi

Setelah model diujikan, hasil evaluasi akan dibandingkan untuk menentukan model yang memiliki kinerja terbaik dalam memprediksi serangan jantung dini. Pengukuran kinerja model didasarkan pada metrik yang telah disebutkan di atas (akurasinya, presisi, recall, dan F1-score), dan hasilnya akan dilaporkan secara rinci. Model yang paling optimal akan dipilih untuk analisis lebih lanjut dan akan dibandingkan dengan metode diagnostik konvensional (seperti pemeriksaan medis tradisional) untuk menilai peningkatan potensi deteksi dini serangan jantung.

3. HASIL DAN PEMBAHASAN

3.1. Model Support Vector Machine (SVM)

Berdasarkan hasil *confusion matrix*, model menunjukkan performa yang cukup baik dalam mengenali kedua kelas (Normal dan *Heart Disease*). Terdapat 71 pasien normal (0) yang berhasil diprediksi dengan benar sebagai normal (*True Negative*), sementara 11 pasien normal (0) salah diprediksi sebagai penderita sakit jantung (*False Positive*). Pada sisi lain, terdapat 93 pasien sakit jantung (1) yang diprediksi benar sebagai penderita sakit jantung (*True Positive*), dan hanya 9 pasien sakit jantung (1) yang salah diprediksi sebagai normal (*False Negative*). Hasil ini menunjukkan bahwa kesalahan model relatif kecil, baik dalam bentuk *False Positive* maupun *False Negative*, sehingga model dapat dikatakan cukup andal dalam mengklasifikasikan kondisi pasien (Gambar 1).



Gambar 1 Confusion Matrix SVM

Evaluasi model melalui classification report juga menunjukkan performa yang konsisten pada kedua kelas.

a. Kelas Normal (0):

Precision sebesar 0.89 menunjukkan bahwa dari semua pasien yang diprediksi normal, 89% benar-benar normal. *Recall* sebesar 0.87 menunjukkan bahwa dari seluruh pasien yang memang normal, 87% berhasil dikenali oleh model. Nilai *F1-Score* sebesar 0.88 menandakan keseimbangan yang baik antara *precision* dan *recall*.

b. Kelas Heart Disease (1):

Precision sebesar 0.89 berarti dari seluruh prediksi pasien sakit jantung, 89% benar adanya. *Recall* sebesar 0.91 menunjukkan bahwa model berhasil mengenali 91% pasien yang benar-benar sakit jantung. Dengan *F1-Score* sebesar 0.90, performa model dalam mendeteksi penyakit jantung dapat dikategorikan sangat baik dan konsisten.

Akurasi Keseluruhan:

Nilai akurasi yang dicapai adalah 0.89 (89%), yang berarti 89% dari seluruh data pasien dapat diprediksi dengan benar oleh model.

Macro Average dan Weighted Average:


Kedua nilai rata-rata ini sama-sama berada pada 0.89, mengindikasikan bahwa dataset relatif seimbang antara pasien normal dan pasien dengan penyakit jantung, serta performa model konsisten di kedua kelas (Gambar 2).

Classification Report:				
	precision	recall	f1-score	support
Normal (0)	0.89	0.87	0.88	82
Heart Disease (1)	0.89	0.91	0.90	102
accuracy			0.89	184
macro avg	0.89	0.89	0.89	184
weighted avg	0.89	0.89	0.89	184

Gambar 2 Classification Report SVM

3.2. Model Random Forest

Berdasarkan hasil *confusion matrix*, model *Random Forest* menunjukkan peningkatan performa dibandingkan model SVM. Terdapat 71 pasien normal yang berhasil diprediksi dengan benar sebagai normal (*True Negative*), sedangkan 11 pasien normal salah diprediksi sebagai sakit jantung (*False Positive*). Pada sisi lain, terdapat 95 pasien sakit jantung yang diprediksi benar sebagai sakit jantung (*True Positive*), sementara hanya 7 pasien sakit jantung yang salah diprediksi sebagai normal (*False Negative*). Gambar (3)



Gambar 3 Confusion Matrix Random Forest

Evaluasi model lebih lanjut melalui classification report memperlihatkan performa yang konsisten pada kedua kelas:

a. Kelas Normal (0):

Precision = 0.91, artinya dari semua prediksi normal, 91% benar-benar normal. *Recall* = 0.87, artinya dari seluruh pasien yang memang normal, 87% berhasil dikenali oleh model. *F1-score* = 0.89, menunjukkan keseimbangan yang baik antara *precision* dan *recall*.

b. Kelas Heart Disease (1):

Precision = 0.90, artinya dari semua prediksi sakit, 90% benar. *Recall* = 0.93, artinya model mampu mengenali 93% pasien yang benar-benar sakit jantung. *F1-score* = 0.91, menandakan performa yang sangat baik dalam mendeteksi penyakit jantung.

Akurasi Keseluruhan model Random Forest mencapai akurasi 0.90 (90%), lebih tinggi dibandingkan model SVM sebelumnya yang hanya mencapai 0.89 (89%).

Macro Average & Weighted Average:

Kedua metrik bernilai 0.90, mengindikasikan bahwa dataset relatif seimbang dan model bekerja baik pada kedua kelas secara merata. (Gambar 4)

Classification Report:				
	precision	recall	f1-score	support
Normal (0)	0.91	0.87	0.89	82
Heart Disease (1)	0.90	0.93	0.91	102
accuracy			0.90	184
macro avg	0.90	0.90	0.90	184
weighted avg	0.90	0.90	0.90	184

Gambar 4 Classification Report Random Forest

Kedua model memiliki performa yang cukup baik dengan akurasi tinggi, yaitu 89% untuk SVM dan 90% untuk Random Forest. Meskipun perbedaannya relatif kecil, Random Forest menunjukkan keunggulan pada hampir semua metrik evaluasi.

Pada kelas Normal (0), nilai *precision* Random Forest (0,91) sedikit lebih tinggi dibandingkan SVM (0,89), sementara *recall* keduanya sama (0,87). Hal ini menunjukkan bahwa Random Forest lebih mampu meminimalisasi kesalahan dalam memprediksi pasien sehat sebagai sakit, meskipun sensitivitas keduanya terhadap pasien normal relatif sama.

Sementara itu, pada kelas Heart Disease (1), Random Forest memberikan hasil yang lebih baik dengan *precision* 0,90 dan *recall* 0,93 dibandingkan SVM yang memiliki *precision* 0,89 dan *recall* 0,91. Perbedaan ini berarti Random Forest lebih presisi dalam mendeteksi pasien yang benar-benar sakit, sekaligus lebih sensitif karena

mampu mengenali lebih banyak pasien dengan penyakit jantung. Hal tersebut juga tercermin dari jumlah *False Negative* (FN) yang lebih sedikit pada *Random Forest* (7 kasus) dibandingkan dengan SVM (9 kasus). Dalam konteks medis, penurunan FN sangat penting karena kesalahan mengklasifikasikan pasien sakit sebagai sehat berpotensi menimbulkan risiko serius.

Secara keseluruhan, meskipun kedua model menunjukkan performa yang baik, *Random Forest* dapat dianggap lebih unggul dan lebih direkomendasikan untuk prediksi serangan jantung dini, terutama karena nilai recall yang lebih tinggi pada kelas penyakit jantung. Dapat dilihat pada Tabel 1.

Tabel 1 Perbandingan Hasil SVM dan Random Forest

Aspek Evaluasi	SVM	Random Forest
Akurasi	89%	90%
Precision (Kelas Normal / 0)	0.89	0.91
Recall (Kelas Normal / 0)	0.87	0.87
Precision (Kelas Heart Disease / 1)	0.89	0.90
Recall (Kelas Heart Disease / 1)	0.91	0.93
False Negative (FN)	9 kasus	7 kasus
Kinerja Umum	Baik	Lebih Unggul
Kesesuaian untuk Sistem Medis	Cukup Baik	Sangat Direkomendasikan

Hal ini menjadikan *Random Forest* lebih sesuai untuk digunakan dalam sistem pendukung keputusan medis, di mana deteksi dini pasien berisiko merupakan prioritas utama.

4. KESIMPULAN

Berdasarkan hasil yang diperoleh, model *Random Forest* dengan teknik *One-Hot Encoding* untuk variabel kategorik menunjukkan performa yang lebih baik dibandingkan dengan model SVM (RBF) dalam memprediksi serangan jantung dini. *Random Forest* mencapai akurasi 90% dan recall 93% untuk kelas *Heart Disease* (1), yang lebih tinggi dibandingkan dengan SVM. Hal ini menunjukkan bahwa *Random Forest* lebih sensitif dalam mendeteksi pasien yang berisiko terkena serangan jantung, yang sangat krusial dalam konteks medis. Selain itu, *Random Forest* juga berhasil mengurangi jumlah *False Negative* (FN), yang menunjukkan lebih sedikit pasien sakit jantung yang tidak terdeteksi. Meskipun demikian, SVM (RBF) juga menunjukkan performa yang baik dengan akurasi 89%, dan masih layak digunakan dalam aplikasi serupa, terutama ketika waktu pemrosesan lebih menjadi pertimbangan.

DAFTAR PUSTAKA

- [1] P. Rahayu, "Perancangan Aplikasi Diagnosa Penyakit Jantung Menggunakan Metode Forward Chaining," *Jurnal Santi - Sistem Informasi Dan Teknik Informasi*, 2023, doi: 10.58794/santi.v1i3.337.
- [2] F. Fredilio, J. Rahmad, S. H. Sinurat, D. R. Hamonangan Sitompul, D. J. Ziegel, and E. Indra, "Perbandingan Algoritma K-Nearest Neighbors (K-Nn) Dan Random Forest Terhadap Penyakit Gagal Jantung," *Jurnal Teknologi Informatika Dan Komputer*, 2023, doi: 10.37012/jtik.v9i1.1432.
- [3] N. Fajriati and B. Prasetyo, "Optimasi Algoritma Naive Bayes Dengan Diskritisasi K-Means Pada Diagnosis Penyakit Jantung," *Jurnal Teknologi*

- Informasi Dan Ilmu Komputer*, 2023, doi: 10.25126/jtiik.20231036510.
- [4] A. Masruriyah, H. Y. Novita, C. Sukmawati, A. Ramadhan, S. Arif, and B. A. Dermawan, "Pengukuran Kinerja Model Klasifikasi Dengan Data Oversampling Pada Algoritma Supervised Learning Untuk Penyakit Jantung," *Computer Science (Co-Science)*, 2024, doi: 10.31294/coscience.v4i1.2389.
- [5] S. C. Dwi Astuti and N. Olii, "Heart Disease Risk Factors in Adolescent Women," *Jambura Journal of Health Sciences and Research*, 2022, doi: 10.35971/jjhsr.v4i2.13434.
- [6] A. Nurmasani and Y. Pristyanto, "Algoritme Stacking Untuk Klasifikasi Penyakit Jantung Pada Dataset Imbalanced Class," *Pseudocode*, 2021, doi: 10.33369/pseudocode.8.1.21-26.
- [7] J. Pradono and A. Werdhasari, "Faktor Determinan Penyakit Jantung Koroner Pada Kelompok Umur 25-65 Tahun Di Kota Bogor, Data Kohor 2011-2012," *Buletin Penelitian Kesehatan*, 2018, doi: 10.22435/bpk.v46i1.48.
- [8] P. A. Widyaswara Suwaryo *et al.*, "Melangkah Menuju Hidup Sehat: Peningkatan Pengetahuan Keluarga Tentang Pencegahan Penyakit Jantung Koroner," *JPP*, 2023, doi: 10.32584/jpp.v2i2.2185.
- [9] A. Alkhusari, M. Handayani, M. A. Sasmita Saputra, and M. Rhomadhon, "Analisis Kejadian Penyakit Jantung Koroner Di Poliklinik Jantung," *Jurnal Aisyiyah Medika*, 2020, doi: 10.36729/jam.v5i2.758.
- [10] W. Ben Ali *et al.*, "Implementing Machine Learning in Interventional Cardiology: The Benefits Are Worth the Trouble," *Front Cardiovasc Med*, 2021, doi: 10.3389/fcvm.2021.711401.
- [11] B. Rahman, B. S. Sabarguna, H. S. Warnars, and W. Budiharto, "Early Detection of Heart Disease Based on Medical Check-Up Datasets Using Multilayer Perceptron Classifier," 2023, doi: 10.21203/rs.3.rs-2992373/v1.
- [12] R. Yilmaz and F. H. Yağın, "Early Detection of Coronary Heart Disease Based on Machine Learning Methods," *Medical Records*, 2022, doi: 10.37990/medr.1011924.
- [13] S. M. Paschalis, D. K. Yanti Hutapea, and K. O. Bachri, "Heart Sound Processing for Early Diagnostic of Heart Abnormalities Using Support Vector Machine," *Jurnal Eltikom*, 2024, doi: 10.31961/eltikom.v8i1.1031.
- [14] P. Agudo-Montore, G. Stuart, D. Wilson, G. Spentzou, R. Sidiqqi, and M. C. Gonzalez Corcia, "Role of New Generation Implantable Loop Recorders in Managing Undiagnosed Pediatric Cardiac Symptoms," 2024, doi: 10.21203/rs.3.rs-4655922/v1.
- [15] J. Liao, L. Huang, M. Qu, B. Chen, and G. Wang, "Artificial Intelligence in Coronary CT Angiography: Current Status and Future Prospects," *Front Cardiovasc Med*, 2022, doi: 10.3389/fcvm.2022.896366.