

Pengembangan Model Klasifikasi Aritmia Pada Lansia Menggunakan Algoritma Support Vector Machine (SVM) Berbasis Data EKG

Muhammad Rizki^{1,*}, Alfrendo Sinaga², Fide Moses Mendrofa³, Bram Dimpos Fajar Sinaga⁴, Agung Prabowo⁵

Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Prima Indonesia, Medan, Indonesia

Email: ^{1,*}yardanrizki@gmail.com, ²alfren.medan2018@gmail.com, ³Fidemendrofa@gmail.com, ⁴bramdfsina96@gmail.com,

⁵agungprabowo@unprimdn.ac.id

Email Penulis Korespondensi: yardanrizki@gmail.com

Submitted 09-06-2025; Accepted 10-07-2025; Published 14-08-2025

Abstrak

Aritmia merupakan salah satu gangguan irama jantung yang berisiko tinggi terhadap kematian, terutama pada kelompok lanjut usia. Lansia memiliki perubahan fisiologis pada struktur dan fungsi jantung yang menyebabkan peningkatan potensi gangguan listrik jantung. Penelitian ini bertujuan untuk mengembangkan model klasifikasi aritmia berbasis sinyal elektrokardiogram (EKG) pada lansia menggunakan algoritma Support Vector Machine (SVM). Data dikumpulkan dari tiga panti jompo dengan total 184 subjek berusia 50–75 tahun menggunakan perangkat Smart Holter EKG 5-lead. Tahapan penelitian meliputi akuisisi sinyal EKG, preprocessing sinyal (baseline correction dan filtering menggunakan Butterworth filter), ekstraksi fitur fisiologis (interval PR, QRS, QT, RR, segmen ST, heart rate, rasio R/S), serta pelabelan data oleh dokter spesialis. Model dilatih dan diuji dengan pendekatan hold-out menggunakan rasio 80:20 serta stratifikasi kelas. Hasil evaluasi menunjukkan performa tinggi dengan akurasi 96,36% pada data pelatihan dan 94,57% pada data pengujian. Nilai Area Under Curve (AUC) mencapai 0.99 secara micro-average dan 0.98–1.00 untuk tiap kelas. Penelitian ini menunjukkan bahwa SVM efektif dalam mengklasifikasikan aritmia pada lansia dan dapat menjadi alat bantu diagnosis dini yang akurat dan efisien.

Kata Kunci: Aritmia; elektrokardiogram; Lansia; Klasifikasi; Support Vector Machine

Abstract

Arrhythmia is one of the most dangerous heart rhythm disorders, especially for the elderly, due to degenerative changes in cardiac structure and function. This study aims to develop an electrocardiogram (ECG)-based arrhythmia classification model for the elderly using the Support Vector Machine (SVM) algorithm. Data were collected from three nursing homes with a total of 184 subjects aged 50–75 years using the Smart Holter ECG 5-lead device. The research stages included ECG signal acquisition, signal preprocessing (baseline correction and Butterworth filter), physiological feature extraction (PR, QRS, QT, RR intervals, ST segment, heart rate, R/S ratio), and data labeling by cardiologists. The model was trained and tested using a hold-out approach with an 80:20 ratio and class stratification. Evaluation results showed high performance with 96.36% accuracy on the training set and 94.57% accuracy on the testing set. The Area Under Curve (AUC) reached 0.99 in micro-average and 0.98–1.00 for each class. This research confirms that SVM is effective for arrhythmia classification in the elderly and has potential as an accurate and efficient diagnostic tool.

Keywords: Arrhythmia; Electrocardiogram; Elderly; Classification; Support Vector Machine

1. PENDAHULUAN

Penyakit kardiovaskular ialah salah satu faktor dominan penyebab kematian di seluruh dunia. dengan WHO mencatat sekitar 17 juta kematian per tahun, mencakup hampir 30% dari seluruh kematian global [1]. Di antara penyebab utama kematian kardiovaskular tersebut, aritmia – gangguan irama jantung – menjadi salah satu kondisi yang paling mematikan. Aritmia dapat menyebabkan berbagai dampak serius, seperti stroke, gagal jantung, bahkan kematian mendadak [2]. Aritmia sendiri merupakan kelainan pada aktivitas listrik jantung yang mengakibatkan ritme jantung menjadi sangat cepat (takikardia), sangat lambat (bradikardia), atau tidak beraturan (fibrilasi). Gangguan ini terjadi akibat kelainan dalam frekuensi, keteraturan, asal impuls listrik, atau jalur konduksi dalam jantung [3]. Apabila tidak dideteksi dan ditangani sejak dini, aritmia dapat berkembang menjadi kondisi fatal yang sulit ditangani secara medis.

Kelompok usia lanjut atau lansia merupakan populasi yang paling rentan terhadap aritmia. Menurut Undang-Undang Nomor 13 Tahun 1998, lansia didefinisikan sebagai individu berusia 60 tahun ke atas. Pada kelompok ini, proses degeneratif yang terjadi dalam tubuh memengaruhi struktur dan fungsi jantung, seperti penurunan elastisitas miokardium, perubahan konduktivitas listrik, dan pembentukan jaringan fibrosis [1][4]. Selain itu, keberadaan komorbiditas seperti hipertensi, diabetes, dan penyakit jantung koroner semakin meningkatkan risiko terjadinya aritmia [5]. Deteksi dini menjadi kunci dalam penanganan aritmia. Salah satu metode utama yang digunakan dalam dunia medis untuk mendeteksi gangguan ini adalah Elektrokardiogram (EKG). EKG merupakan alat diagnostik yang merekam aktivitas listrik jantung melalui elektroda yang dipasang di permukaan kulit. Dengan alat ini, tenaga medis dapat mengevaluasi ritme jantung, mendeteksi potensi gangguan irama, serta menganalisis pengaruh obat terhadap fungsi jantung [6][7]. Teknologi EKG telah berkembang dari alat stasioner menjadi perangkat portabel seperti Smart Holter EKG 5 Lead, yang memungkinkan pemantauan jantung secara kontinu dan real-time [8].

Namun, analisis sinyal EKG secara manual memerlukan keahlian tinggi dan waktu yang cukup lama. Hal ini menjadi tantangan tersendiri terutama dalam sistem pelayanan kesehatan yang serba cepat. Oleh karena itu, pendekatan berbasis kecerdasan buatan (Artificial Intelligence/AI), khususnya machine learning, mulai banyak diterapkan untuk membantu proses klasifikasi dan diagnosis aritmia secara otomatis [9]. Salah satu algoritma machine learning yang sangat terkenal dan telah terbukti efektif dalam klasifikasi data kesehatan adalah Support Vector Machine (SVM). SVM

merupakan metode pembelajaran terawasi yang bekerja dengan membangun hyperplane sebagai batas pemisah antar kelas data. Keunggulan utama SVM terletak pada kemampuannya dalam menangani data berdimensi tinggi dan menghasilkan margin klasifikasi maksimum yang mampu meningkatkan generalisasi model [10]. Selain itu, SVM memiliki fleksibilitas tinggi karena bisa menggunakan berbagai jenis kernel, seperti Radial Basis Function (RBF), dalam menangani data yang tidak linear [11].

Dalam beberapa studi terdahulu, algoritma SVM telah digunakan secara luas untuk menganalisis dan mengklasifikasi sinyal EKG. Misalnya, pada penelitian oleh Ayuni, Wihandika, dan Yudistira (2021), SVM mampu melakukan klasifikasi aritmia dengan akurasi tinggi setelah melalui tahapan ekstraksi fitur dari sinyal EKG [12]. Penelitian lain yang dilakukan oleh Nugraha et al. (2023) menemukan bahwa kombinasi Discrete Wavelet Transform (DWT) dan SVM mampu meningkatkan performa klasifikasi aritmia hingga mencapai akurasi 73,57% pada dekomposisi level 1 [13]. Kendati demikian, penerapan algoritma SVM secara khusus untuk klasifikasi aritmia pada lansia masih jarang dilakukan. Padahal, karakteristik fisiologis lansia berbeda dengan individu muda maupun dewasa. Lansia memiliki morfologi sinyal EKG yang lebih kompleks akibat proses degeneratif dan perubahan metabolisme tubuh [14][15]. Oleh karena itu, diperlukan pengembangan model klasifikasi yang secara khusus disesuaikan dengan karakteristik kelompok usia ini. Selain itu, sebagian besar penelitian sebelumnya belum menerapkan pelabelan risiko aritmia secara klinis berdasarkan data lansia, dan belum mengevaluasi performa model secara menyeluruh menggunakan metrik yang seimbang. Hal ini menunjukkan adanya gap dalam literatur yang ingin diisi oleh penelitian ini.

Untuk mendukung pembangunan model klasifikasi yang akurat, data EKG yang diperoleh harus melalui tahapan pra-pemrosesan (preprocessing), seperti koreksi baseline, filtering noise menggunakan Butterworth filter, hingga normalisasi skala fitur dengan StandardScaler [16]. Fitur-fitur penting yang digunakan antara lain interval PR, QRS, QT, RR, segmen ST, rasio amplitudo gelombang R/S, dan heart rate. Seluruh fitur ini akan digunakan sebagai vektor input dalam proses pelatihan model. Selanjutnya, proses pelabelan data dilakukan oleh tenaga medis profesional untuk memastikan validitas klinis dari data yang digunakan. Klasifikasi sinyal EKG dilakukan dalam empat kategori berdasarkan parameter fisiologisnya: normal, abnormal, berpotensi aritmia, dan sangat berpotensi aritmia. Kategori ini merepresentasikan tingkat risiko berdasarkan nilai-nilai fisiologis pada sinyal EKG [17][18]. Penelitian ini dilakukan sebagai upaya untuk mengisi kekosongan riset yang secara khusus mengembangkan sistem klasifikasi aritmia berbasis SVM bagi kelompok lansia. Dengan membangun model yang dirancang untuk mengenali kondisi lansia, sistem ini diharapkan dapat menjadi alat bantu diagnosis yang lebih akurat, cepat, dan adaptif terhadap kebutuhan klinis. Evaluasi model dilakukan tidak hanya berdasarkan nilai akurasi, tetapi juga mempertimbangkan presisi, recall, F1-score, serta area under the curve (AUC) dari kurva ROC, untuk memastikan performa model merata pada tiap kelas aritmia.


Seiring meningkatnya kebutuhan akan sistem kesehatan cerdas berbasis teknologi, penelitian ini diharapkan menjadi kontribusi langsung dalam pengembangan sistem deteksi aritmia otomatis yang dapat diimplementasikan di lingkungan rumah sakit, klinik, hingga sistem pemantauan mandiri bagi lansia di rumah. Selain itu, hasil penelitian ini juga berpotensi menjadi fondasi bagi pengembangan sistem lanjutan dengan mengombinasikan algoritma lain seperti CNN dan LSTM untuk mencapai tingkat keakuratan yang lebih tinggi.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menerapkan pendekatan kuantitatif sebagai metode ilmiah yang sistematis untuk menganalisis hubungan antar variabel fisiologis dalam mendeteksi aritmia berdasarkan sinyal EKG pada lansia. Algoritma klasifikasi yang digunakan adalah SVM, dengan pelatihan berdasarkan fitur-fitur fisiologis yang diekstraksi dari sinyal EKG subjek lansia.

Penelitian dilaksanakan pada periode Desember 2024 hingga Juni 2025. Pengumpulan data dilakukan di tiga panti jompo mitra, sementara pengolahan dan analisis dilakukan di Universitas Prima Indonesia Medan. Secara umum, tahapan penelitian meliputi akuisisi sinyal EKG, filtering, ekstraksi fitur, pembersihan data, pelabelan, normalisasi, pelatihan model, dan evaluasi. Alur tahapan tersebut disajikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Gambar 1 memperlihatkan proses dimulai dari pemasangan elektroda pada tubuh subjek lansia yang terhubung ke perangkat Smart Holter ECG 5-Lead. Sinyal EKG direkam dalam bentuk data digital ADC 24-bit dan ditransmisikan ke laptop melalui Bluetooth. Sinyal tersebut kemudian difilter menggunakan bandpass filter, notch filter, dan koreksi baseline untuk menghilangkan noise dan gangguan.

Setelah filtering, fitur sinyal diekstraksi menggunakan NeuroKit2 dan DWT untuk menghasilkan parameter fisiologis seperti interval RR, PR, QT, segmen ST, rasio R/S, dan detak jantung. Fitur-fitur ini kemudian melalui tahap cleaning (menghapus data duplikat, outlier, dan missing values), dilabeli berdasarkan interpretasi medis, serta dinormalisasi dengan metode z-score. Dataset yang telah siap digunakan untuk pelatihan model klasifikasi SVM dan dievaluasi untuk menilai performanya dalam mengenali aritmia.

2.2 Alat dan Dataset

Penelitian ini memanfaatkan sejumlah alat dan bahan yang dipaparkan di Tabel 1.

Tabel 1. Alat yang digunakan pada Penelitian

No	Spesifikasi	Alat yg Digunakan
1	Alat	Smart Holter EKG 5-Lead
2	Kabel Elektroda	Kabel Electroda 3-lead (2pcs)
3	EKG Elekktroda	EKG Electroda (612)
4	Baterai	Baterai Li-ion (2pcs)
5	Charger Baterai	Charger Baterai LI-ion
6	Laptop	LENOVO Ideapad Gaming 3 15ARH7

Pada penelitian ini dataset diperoleh langsung dari tiga pantijompo mitra dengan total 184 data EKG. Data yang dikumpulkan dibatasi pada rentang usia 50 hingga 75 tahun dan terdiri dari subjek laki-laki maupun perempuan. Rincian struktur dan karakteristik awal dari dataset yang digunakan dapat dilihat pada Tabel 2.


Table 2. Dataset Penelitian

subjek	rr	Pr	qrs	qt	st	r/s ratio	bpm
1	798.9898990	110.1928375	69.6969697	267.2176309	164.9831650	2.4946246	75.0948167
2	966.2500000	156.2500000	64.2857143	237.5000000	148.0000000	4.3930307	62.0957309
3	789.0011223	145.2020202	69.4444444	200.7575758	111.1111111	2.2068542	76.0455192
.....							
100	848.4848485	142.4242424	78.5634119	239.3939394	89.0725436	1.7129539	70.7142857
101	691.9191919	118.6868687	56.0146924	246.6329966	158.5081585	1.3468609	86.7153285
102	701.1784512	104.3771044	80.8080808	205.3872054	107.2261072	2.8028970	85.5702281

2.3 Metode Pengumpulan Data


Data dikumpulkan dengan menggunakan perangkat Smart Holter EKG 5 Lead yang ditempatkan pada tubuh subjek untuk merekam aktivitas listrik jantung secara terus-menerus. Elektroda yang dipasang sesuai standar medis merekam aktivitas kelistrikan jantung, memberikan gambaran lengkap mengenai fungsi jantung. Sinyal yang ditangkap dianalisis untuk

mendeteksi aritmia atau gangguan irama jantung, memungkinkan pengambilan data kontinu yang lebih akurat untuk diagnosis kelainan irama jantung, seperti yang dipaparkan pada Gambar 2.



Gambar 2. Alat Smart Holter EKG 5 Lead

Jack pertama terdiri dari elektroda merah (RA) di dada kanan atas, kuning (LA) di dada kiri atas, dan hijau (RL) di kanan bawah tubuh, menangkap sinyal Lead I, II, dan III. Jack kedua berisi elektroda merah (V1) di sternum kanan, kuning (LL) di kiri bawah tubuh, dan hijau (RL) di kanan bawah tubuh, menangkap sinyal Lead V1. Penempatan elektroda yang tepat memastikan sinyal akurat dan mencerminkan aktivitas jantung. Data dikumpulkan menggunakan alat EKG 5-Lead untuk merekam sinyal listrik jantung secara berkelanjutan, mendeteksi aritmia, dan memberikan gambaran kondisi kelistrikan jantung. Seperti yang diperlihatkan oleh Gambar 3.



Gambar 3. Pemasangan elektroda pada tubuh subjek.

Setelah elektroda terpasang dengan benar, pengukuran dilakukan dalam posisi duduk untuk memastikan data yang diambil mencerminkan kondisi jantung saat istirahat. Sinyal EKG dikirim secara nirkabel melalui koneksi Bluetooth ke laptop dalam bentuk data mentah (raw) berupa nilai ADC 24-bit dari tiga lead utama. Selanjutnya, data ini diolah menggunakan perangkat lunak di lingkungan kampus untuk proses pra-pemrosesan dan analisis lebih lanjut.

2.4. Metode Pengolahan Data

a. Pra-pemrosesan dan Filtering

Tahapan awal pengolahan sinyal EKG dimulai dengan proses pra-pemrosesan terhadap data mentah yang diperoleh dari perangkat Smart Holter ECG 5-Lead. Sinyal yang direkam dari tiga lead (I, II, dan V1) disimpan dalam format .csv sebagai nilai digital 24-bit dari ADC (Analog-to-Digital Converter) [19]. Nilai ini masih berupa data mentah dan belum merepresentasikan satuan fisiologis sebenarnya. Oleh karena itu, dilakukan konversi ke satuan milivolt (mV) menggunakan rumus konversi standar. Rumus yang digunakan ditunjukkan pada Persamaan (1) :

$$EKG(mV) = ADC \times \left(\frac{2.4}{2^{24}} \right) \times 100 \quad (1)$$

Rumus ini memastikan sinyal mencerminkan tegangan listrik aktual dari aktivitas jantung. Setelah konversi, sinyal EKG kemudian melalui proses filtering untuk menghilangkan artefak dan gangguan:

1. Koreksi baseline wander dilakukan untuk mengatasi pergeseran sinyal akibat pemapasan atau gerakan tubuh pasien. Teknik yang digunakan bisa berupa median filter atau detrending.
2. Bandpass filter Butterworth (0,5–40 Hz) digunakan untuk menyaring komponen frekuensi relevan dan membuang noise di luar rentang normal sinyal jantung.
3. Notch filter atau FIR filter diterapkan untuk mereduksi interferensi dari frekuensi listrik 50/60 Hz.

Hasil dari tahapan ini adalah sinyal EKG yang bersih dan stabil, siap untuk digunakan dalam tahap ekstraksi fitur.

b. Ekstraksi Fitur

Setelah sinyal EKG dibersihkan, langkah selanjutnya adalah ekstraksi fitur penting yang merepresentasikan aktivitas listrik jantung. Proses ini dilakukan menggunakan NeuroKit2 dan Discrete Wavelet Transform (DWT), yang mampu menangkap informasi baik dalam domain waktu maupun frekuensi.

1. Fitur-fitur yang diambil meliputi:
2. Interval RR: rata-rata dan standar deviasi antar detak jantung
3. Interval PR dan QT: waktu antara gelombang-gelombang utama pada siklus jantung
4. Segmen ST: indikator potensi iskemia atau abnormalitas lainnya
5. Rasio amplitudo gelombang R/S pada lead V1
6. Heart Rate: detak jantung per menit (bpm)

Semua fitur tersebut diubah menjadi bentuk vektor numerik dan digunakan sebagai input utama dalam model klasifikasi berbasis pembelajaran mesin.

c. Cleaning Data

Setelah seluruh fitur berhasil diekstraksi dari sinyal EKG, dilakukan proses data cleaning untuk memastikan akurasi dan integritas data sebelum masuk ke tahap pelabelan. Tahapan ini mencakup penanganan nilai-nilai ekstrem atau tidak wajar berdasarkan batas fisiologis, serta pengecekan data duplikat yang dapat mengganggu proses pelatihan model. Penyesuaian dilakukan secara hati-hati untuk menjaga kualitas dan representativitas dataset tanpa menghilangkan informasi penting.

d. Pelabelan Dataset

Setelah melalui tahap pembersihan, data diberi label klasifikasi berdasarkan interpretasi medis dari parameter fisiologis seperti interval RR, PR, QRS, QT, segmen ST, heart rate, dan rasio R/S. Proses pelabelan ini dilakukan oleh tenaga medis profesional, yaitu dokter spesialis jantung, yang melakukan evaluasi terhadap setiap segmen sinyal EKG dengan mempertimbangkan pola waktu, amplitudo sinyal, dan indikator klinis relevan untuk mendeteksi potensi aritmia. Berdasarkan evaluasi klinis, tiap segmen dikategorikan menjadi Normal, Abnormal, Berpotensi Aritmia, atau Sangat Berpotensi Aritmia sesuai kriteria medis dalam Tabel 3. Pelabelan ini dilakukan untuk memastikan validitas medis dataset yang digunakan dalam proses pelatihan model, sehingga hasil klasifikasi yang dihasilkan dapat diandalkan dalam aplikasi nyata.

Tabel 3. Rentang parameter ekg untuk setiap klasifikasi

Label	RR Interval (ms)	PR Interval (ms)	QRS Duration (ms)	QT Interval (ms)	ST Segment (ms)	HeartRate (bpm)	R/S Ratio
Normal	600 - 1000	120 - 200	60 - 100	350 - 440	80 - 120	60 - 100	< 1
Abnormal	< 600	< 120	< 60	< 350	< 80	< 60	> 1
Berpotensi Aritmia	600 - 1000	190 - 200	101 - 120	441 - 460	120 - 130	101 - 110	> 1
Sangat Berpotensi Aritmia	600 - 1000	> 200	> 120	> 460	> 130	> 111	> 1

e. Normalisasi

Setelah proses pelabelan oleh tenaga medis dilakukan dan seluruh sampel diklasifikasikan ke dalam kategori yang sesuai, tahap berikutnya adalah normalisasi fitur numerik. Seluruh fitur yang telah diekstraksi dari sinyal EKG dinormalisasi untuk menghindari dominasi fitur dengan skala besar terhadap fitur lainnya dalam pembentukan model. Normalisasi dilakukan menggunakan metode standardisasi z-score agar setiap fitur memiliki rata-rata nol dan deviasi standar satu. Proses normalisasi ini diformulasikan dalam Persamaan (2) :

$$x_{baru} = \frac{x - \mu}{\sigma} \quad (2)$$

di mana x adalah nilai asli, μ adalah rata-rata, dan σ adalah deviasi standar dari fitur tersebut. Normalisasi memastikan fitur dengan skala besar tidak mengganggu hasil prediksi, dan membuat setiap fitur berpengaruh secara seimbang dalam pembelajaran.

e. Split Data

Setelah proses normalisasi, data dibagi menjadi dua subset: 80% untuk pelatihan (training) dan 20% untuk pengujian (testing). Pembagian ini memungkinkan evaluasi performa model secara objektif terhadap data yang tidak pernah dilihat saat pelatihan. Tujuan dari split data ini adalah memastikan generalisasi model yang baik dan mencegah overfitting. Teknik ini merupakan praktik standar dalam pengujian model pembelajaran mesin.

f. Klasifikasi dengan SVM

Model klasifikasi yang digunakan dalam penelitian ini adalah SVM berbasis kernel RBF. Algoritma ini dipilih karena kemampuannya dalam membentuk decision boundary non-linear dan efektif untuk data berukuran kecil hingga sedang. Fungsi kernel RBF yang digunakan dalam proses transformasi ke ruang berdimensi tinggi dituliskan pada Persamaan (3):

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3)$$

Parameter γ mengontrol tingkat pengaruh satu titik data terhadap titik lainnya. Selain itu, digunakan parameter regulasi C untuk menyeimbangkan antara kompleksitas model dan tingkat kesalahan klasifikasi.

Dalam pelatihan, model diformulasikan untuk menemukan hyperplane yang menempatkan dua kelas sejauh mungkin dalam ruang fitur. Optimasi dilakukan dengan meminimalkan fungsi objektif seperti ditunjukkan dalam Persamaan (4) :

$$\min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (4)$$

dengan kendala seperti ditunjukkan pada Persamaan (5) :

$$y_i(w \cdot \phi(x_i) + b) \geq 1 - \xi_i, \xi_i \geq 0 \quad (5)$$

di mana ξ_i adalah slack variable dan $\phi(x_i)$ adalah pemetaan ke ruang fitur berdimensi tinggi. Dengan pendekatan ini, SVM mampu mengklasifikasikan sinyal EKG secara efektif berdasarkan fitur fisiologis yang telah diekstraksi sebelumnya [20].

3. HASIL DAN PEMBAHASAN

3.1 Preprocessing dan Ekstraksi Fitur

Proses awal dalam penelitian ini dimulai dari akuisisi sinyal EKG menggunakan perangkat ECG 5-lead. Sinyal yang diperoleh masih dalam kondisi mentah, mengandung noise serta gangguan seperti baseline wander, sehingga diperlukan tahap preprocessing untuk meningkatkan kualitas sinyal sebelum dianalisis lebih lanjut.

Tahapan preprocessing terdiri dari empat langkah utama, yaitu:

a. Visualisasi Awal

Sinyal EKG mentah ditampilkan terlebih dahulu untuk memperoleh gambaran kondisi awal serta mengidentifikasi gangguan visual seperti noise atau pergeseran garis dasar akibat artefak gerakan.

b. Baseline Correction

Langkah selanjutnya adalah koreksi baseline, yang dilakukan untuk mengatasi pergeseran garis dasar (baseline drift) akibat aktivitas pernapasan atau gerakan tubuh pasien. Proses ini penting untuk menstabilkan garis dasar sinyal sebelum filtrasi lebih lanjut.


c. Butterworth Filtered

Sinyal kemudian difilter menggunakan Butterworth filter orde rendah, dengan rentang frekuensi antara 0.5–40 Hz. Tujuannya adalah menghilangkan komponen frekuensi rendah (misalnya artefak gerakan) maupun frekuensi tinggi (high-frequency noise), sambil mempertahankan komponen utama gelombang EKG yang relevan.

d. Visualisasi Akhir


Langkah terakhir adalah menampilkan hasil akhir setelah proses preprocessing. Visualisasi ini bertujuan memastikan bahwa sinyal telah cukup bersih dan siap untuk proses ekstraksi fitur.

Visualisasi dari seluruh tahapan preprocessing ditunjukkan secara berurutan pada Gambar 4, yang memperlihatkan perbandingan sinyal EKG sebelum dan sesudah dilakukan tahapan preprocessing.



Gambar 4. Visualisasi sinyal EKG sebelum dan sesudah preprocessing: (a) sinyal mentah, (b) sinyal setelah preprocessing

Setelah sinyal berhasil diproses, dilakukan ekstraksi fitur dengan mendeteksi puncak gelombang P, Q, R, S, dan T secara otomatis. Deteksi ini dilakukan dengan mempertimbangkan hubungan spasial antar puncak dan penggunaan parameter *threshold* amplitudo adaptif. Hasilnya menunjukkan bahwa morfologi gelombang PQRST dapat dikenali secara jelas dan konsisten di setiap siklus jantung. Visualisasi hasil deteksi puncak Terpapar dengan jelas dalam Gambar 5.



Gambar 5. Hasil deteksi puncak gelombang PQRST pada sinyal EKG setelah preprocessing.

3.2 Cleaning Data

Proses pembersihan data dilakukan untuk menjamin kualitas dan validitas sinyal EKG sebelum tahap pelabelan dan pemodelan. Langkah ini mencakup deteksi serta penghapusan data duplikat, koreksi nilai-nilai yang berada di luar rentang fisiologis normal, serta penyesuaian format agar struktur data seragam. Tidak semua anomali langsung dihapus; beberapa disesuaikan berdasarkan justifikasi medis untuk mencegah kehilangan informasi penting yang masih relevan

3.3 Pelabelan Data

Setelah proses ekstraksi fitur selesai dilakukan, data diklasifikasikan berdasarkan hasil evaluasi medis oleh dokter spesialis jantung. Proses pelabelan ini mempertimbangkan sejumlah parameter fisiologis utama, seperti interval RR, PR, QRS, QT, segmen ST, laju detak jantung, dan rasio gelombang R/S. Penilaian dilakukan secara menyeluruh dengan mempertimbangkan pola temporal sinyal, amplitudo tiap segmen gelombang, serta indikator klinis yang relevan untuk mendeteksi potensi gangguan ritme jantung. Analisis tiap segmen sinyal EKG menentukan klasifikasinya ke dalam empat kelompok: Normal, Abnormal, Berpotensi Aritmia, dan Sangat Berpotensi Aritmia.

Untuk memberikan gambaran yang lebih terstruktur, Tabel 4 merangkum kriteria utama yang digunakan dalam pelabelan kelas tersebut. Penentuan ini mengacu pada batas fisiologis yang umum digunakan dalam praktik klinis serta standar evaluasi aritmia terkini. Penyusunan label bertujuan memastikan validitas klinis dari dataset yang akan digunakan dalam proses pelatihan model, sehingga model tidak hanya akurat secara statistik, tetapi juga relevan dalam konteks aplikasi medis.

Tabel 4. Kriteria Klinis untuk Pelabelan Data EKG


Kelas	Label	Kriteria Klinis Utama
0	Normal	Semua parameter fisiologis berada dalam rentang normal
1	Abnormal	Terdapat 1–2 parameter menyimpang ringan, tanpa indikasi klinis berat
2	Berpotensi Aritmia	Terdapat pola tidak stabil pada RR atau anomali pada segmen ST
3	Sangat Berpotensi Aritmia	Terjadi QT panjang, elevasi ST signifikan, atau morfologi gelombang abnormal

3.4 Normalisasi Data

Selain pelabelan data, tahap penting berikutnya adalah proses normalisasi terhadap fitur-fitur yang telah diekstraksi. Proses ini bertujuan untuk menyelaraskan skala setiap fitur agar tidak terjadi dominasi satu fitur terhadap fitur lainnya dalam proses pelatihan model. Normalisasi dilakukan menggunakan metode *StandardScaler*, yang mentransformasi setiap fitur menjadi memiliki nilai rata-rata mendekati nol dan deviasi standar mendekati satu. Hal ini penting karena sebelum normalisasi, terdapat perbedaan skala yang sangat mencolok antar fitur dalam dataset [21]. Misalnya, fitur interval RR memiliki rentang antara 200 hingga 1200 milidetik, sementara fitur segmen ST hanya berada dalam rentang 50 hingga 400 milidetik. Tanpa penyesuaian skala, algoritma pembelajaran mesin dapat secara tidak langsung lebih menekankan pada fitur dengan rentang nilai lebih besar, sehingga mengabaikan kontribusi fitur yang nilai absolutnya lebih kecil meskipun secara klinis sangat relevan.

Dengan diterapkannya normalisasi, distribusi semua fitur menjadi lebih seragam dan saling tumpang tindih, sehingga setiap fitur memperoleh perlakuan yang adil dalam proses pembelajaran model. Hasilnya, model dapat belajar dari semua fitur secara proporsional tanpa adanya bias terhadap fitur tertentu. Proses ini secara signifikan berkontribusi pada peningkatan performa model, baik dari segi akurasi klasifikasi, stabilitas prediksi, maupun kemampuan generalisasi.

terhadap data baru. Visualisasi hasil transformasi distribusi fitur sebelum dan sesudah normalisasi ditampilkan secara jelas seperti pada Gambar 6.




Gambar 6. Visualisasi distribusi fitur sebelum dan sesudah normalisasi:

(a) Distribusi nilai fitur sebelum normalisasi (b) Distribusi nilai fitur setelah dilakukan normalisasi

Setelah seluruh tahapan preprocessing, ekstraksi fitur, pelabelan, dan normalisasi selesai dilakukan, proses klasifikasi dilakukan menggunakan algoritma SVM. Model dibangun menggunakan kernel RBF, karena kemampuannya menangani pemisahan kelas pada data non linier dan berdimensi tinggi. Proses pelatihan dilakukan menggunakan pustaka *Scikit-learn* di lingkungan Python. Data dibagi menggunakan metode *hold-out* dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Stratifikasi diterapkan agar distribusi label tetap proporsional pada kedua subset data. Parameter penting seperti nilai C (regularisasi) dan γ (kernel coefficient) diatur melalui proses uji coba bertingkat untuk memperoleh konfigurasi model dengan akurasi tinggi namun tetap menghindari overfitting. Pipeline klasifikasi terdiri dari tahapan: pembagian data, normalisasi, pelatihan model, dan evaluasi hasil prediksi. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, dan area under the ROC curve (AUC) untuk tiap kelas prediksi.

3.5 Evaluasi Model pada Data Training dan Testing


Model Support Vector Machine (SVM) pertama kali dievaluasi menggunakan data pelatihan (training) untuk mengukur sejauh mana model mampu mempelajari pola dari data tersebut. Hasil evaluasi pada data training menunjukkan akurasi 96,36%, presisi 96,42%, dan recall 96,80%. Hal ini mengindikasikan bahwa model dapat mengidentifikasi pola dalam data pelatihan secara konsisten dan akurat. Visualisasi confusion matrix pada Gambar 7 memperlihatkan distribusi klasifikasi yang dominan di sepanjang diagonal, yang berarti sebagian besar sampel berhasil diklasifikasikan dengan benar, dengan jumlah kesalahan prediksi yang sangat rendah.



Gambar 7. Confusion Matrix Data Training

Setelah pelatihan berakhir, model akan diuji dengan data uji guna melihat seberapa efektif model dalam menangani data baru yang tidak termasuk dalam data pelatihan. Hasil evaluasi pada data testing menunjukkan akurasi 94,57%, presisi 94,67%, recall 94,57%, dan F1-score 94,58%. Nilai-nilai ini menunjukkan bahwa performa model tetap stabil dan seimbang dalam mengklasifikasikan data baru. Fungsi `train_test_split` dari *scikit-learn* digunakan dalam validasi dengan


pendekatan hold-out, di mana data dialokasikan 80% untuk melatih model dan 20% untuk mengujinya. Stratifikasi diterapkan agar distribusi kelas tetap seimbang pada kedua subset data, sehingga evaluasi performa model menjadi lebih representatif. Hasil pengujian ditampilkan dalam confusion matrix pada Gambar 8 yang menunjukkan pola distribusi dominan pada diagonal, menandakan bahwa model mampu melakukan prediksi dengan akurasi tinggi dan tingkat kesalahan klasifikasi yang sangat rendah.



Gambar 8. Confusion Matrix Data Testing

Secara rinci, hasil klasifikasi per kelas juga menunjukkan performa tinggi. Untuk kelas Normal (kelas 0), model memiliki presisi 0.95 dan recall 0.98. Pada kelas Abnormal (kelas 1), presisi mencapai 0.94 dengan recall 0.92, menunjukkan kemampuan deteksi gangguan dengan sangat akurat. Kelas Berpotensi Aritmia (kelas 2) memiliki presisi 0.92 dan recall 0.96, sedangkan kelas Sangat Berpotensi Aritmia (kelas 3) mencapai presisi 0.93 dan recall 0.89. Nilai-nilai ini menunjukkan bahwa model mampu membedakan dan mengenali semua kelas secara seimbang dan tidak bias terhadap kelas tertentu.

Sebagai evaluasi lanjutan, dilakukan analisis ROC Curve untuk klasifikasi multi-kelas guna mengukur kemampuan model dalam membedakan antar kelas berdasarkan nilai AUC atau Area Under Curve. Hasil evaluasi menunjukkan bahwa setiap kelas memiliki nilai AUC yang sangat tinggi, yaitu 1.00 pada kelas Normal, 0.99 pada kelas Abnormal, 0.99 pada kelas Berpotensi Aritmia, dan 0.98 pada kelas Sangat Berpotensi Aritmia. Selain itu, nilai micro-average AUC mencapai 0.99, yang mencerminkan kinerja model yang sangat baik secara keseluruhan dalam membedakan sinyal EKG antar kategori. ROC curve yang dekat dengan pojok kiri atas mengindikasikan efektivitas model dalam mengklasifikasikan dengan benar (true positive) sambil meminimalkan kesalahan klasifikasi (false positive) pada empat kelas, Sebagaimana divisualisasikan pada Gambar 9.



Gambar 9. ROC Curve Multi-class Classification

Secara keseluruhan, model SVM yang dilatih dan diuji pada dataset sinyal EKG ini menunjukkan performa klasifikasi yang sangat baik, dengan kemampuan generalisasi yang kuat terhadap data baru serta keseimbangan performa antar kelas. Berdasarkan evaluasi melalui confusion matrix, metrik per kelas, dan kurva ROC, model ini sangat potensial untuk diterapkan dalam sistem deteksi aritmia berbasis machine learning di lingkungan klinis maupun sistem pendukung diagnosis otomatis.

3.6 Implementasi Hasil Analisa Penelitian

Implementasi penelitian ini diawali dengan proses pembersihan sinyal EKG mentah yang diperoleh dari perangkat rekam jantung 5-lead. Sinyal mentah tersebut mengandung berbagai gangguan seperti noise frekuensi tinggi, artefak akibat

pergerakan tubuh, serta baseline wander yang disebabkan oleh proses pemapasan. Oleh karena itu, dilakukan serangkaian tahapan preprocessing yang meliputi koreksi baseline dan pemfilteran sinyal menggunakan Butterworth filter dengan rentang frekuensi 0.5–40 Hz. Proses ini bertujuan untuk mempertahankan komponen sinyal utama dan mengeliminasi gangguan yang dapat mengaburkan morfologi gelombang jantung. Hal tersebut sejalan dengan penelitian Putra et al. (2021), yang menunjukkan bahwa preprocessing yang baik dapat meningkatkan rasio sinyal terhadap gangguan dan memperbaiki akurasi deteksi fitur jantung pada sinyal EKG [16]. Setelah sinyal berhasil dibersihkan, sistem mendeteksi secara otomatis puncak gelombang P, Q, R, S, dan T menggunakan algoritma spasial serta penyesuaian threshold amplitudo. Deteksi ini menjadi dasar untuk mengekstraksi fitur-fitur fisiologis penting, seperti interval PR, durasi QRS, interval QT dan RR, segmen ST, heart rate, serta rasio gelombang R/S. Hasil deteksi menunjukkan bahwa morfologi gelombang jantung teridentifikasi secara konsisten pada tiap siklus denyut. Hal tersebut sejalan dengan temuan Ayuni et al. (2021) yang menegaskan bahwa akurasi dalam deteksi gelombang PQRST sangat memengaruhi keberhasilan sistem klasifikasi berbasis pembelajaran mesin, karena fitur-fitur tersebut secara langsung mencerminkan kondisi listrik jantung [12].

Data yang telah diekstrak kemudian diberikan label berdasarkan evaluasi medis oleh dokter spesialis jantung. Segmen-segmen tersebut dibagi menjadi empat kelompok: normal, abnormal, berpotensi aritmia, dan sangat berpotensi aritmia. Penilaian tidak hanya berdasarkan nilai numerik fitur, tetapi juga mempertimbangkan indikasi klinis yang relevan dengan diagnosis aritmia. Keputusan pelabelan manual oleh tenaga medis ini bertujuan memastikan bahwa setiap label memiliki validitas klinis tinggi, sehingga dapat meningkatkan kualitas pembelajaran model. Hal ini sejalan dengan pendapat Mardiah et al. (2024), yang menyatakan bahwa partisipasi profesional medis dalam pelabelan data mampu meminimalkan kesalahan anotasi dan meningkatkan keandalan sistem berbasis supervised learning dalam bidang medis [17]. Selanjutnya, dilakukan normalisasi terhadap seluruh fitur menggunakan metode standarisasi berbasis z-score. Normalisasi ini penting untuk menyamakan skala antar fitur sehingga tidak terjadi dominasi nilai absolut dari fitur tertentu dalam proses pelatihan model. Misalnya, fitur interval RR memiliki rentang jauh lebih besar dibandingkan fitur segmen ST, dan tanpa normalisasi, algoritma SVM cenderung memberikan bobot lebih besar pada fitur yang skala nilainya tinggi. Proses normalisasi terbukti membuat distribusi nilai fitur menjadi lebih seragam, sehingga kontribusi setiap fitur dalam pembelajaran model menjadi lebih proporsional. Hal tersebut sejalan dengan penelitian Nugraha et al. (2023) yang menyatakan bahwa normalisasi data merupakan langkah krusial dalam menjaga kestabilan pelatihan dan menghindari bias dalam model pembelajaran mesin [13].

Model SVM yang dikembangkan dalam penelitian ini dievaluasi menggunakan data training dan data testing secara terpisah. Hasil evaluasi pada data training menunjukkan akurasi mencapai 96,36% dengan presisi dan recall di atas 96%, serta distribusi prediksi yang dominan di diagonal confusion matrix. Hal ini menunjukkan bahwa model mampu mengenali pola fisiologis jantung dengan akurat pada data pelatihan. Evaluasi lanjutan menggunakan data testing menunjukkan akurasi sebesar 94,57%, dengan nilai presisi dan recall yang hampir setara, serta F1-score yang tinggi. Hasil ini mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting. Hal tersebut sejalan dengan temuan Pratama et al. (2021), yang membuktikan bahwa algoritma SVM sangat efisien dalam membedakan pola ritme jantung apabila fitur yang digunakan memiliki nilai diagnostik yang tinggi [22]. Kinerja model juga diperkuat melalui evaluasi menggunakan ROC curve dan nilai Area Under Curve (AUC) yang mendekati sempurna di setiap kelas, yaitu 0.98 hingga 1.00. Hal ini menunjukkan bahwa model mampu membedakan setiap kelas dengan akurasi yang sangat tinggi. Nilai micro-average AUC sebesar 0.99 menunjukkan kestabilan performa model secara keseluruhan dalam klasifikasi multi-kelas. Hal ini sejalan dengan studi Hapsari et al. (2023) yang menekankan pentingnya evaluasi berbasis ROC dan AUC dalam sistem klasifikasi berbasis sinyal fisiologis untuk memastikan bahwa model tidak hanya akurat, tetapi juga memiliki sensitivitas tinggi terhadap tiap kelas yang diprediksi [17]. Secara keseluruhan, implementasi model SVM dalam penelitian ini terbukti efektif dalam mengklasifikasikan aritmia pada lansia, dengan dukungan data yang valid, preprocessing yang optimal, serta proses evaluasi yang ketat dan berimbang. Hal ini memperkuat keyakinan bahwa teknologi machine learning, jika diterapkan dengan prinsip yang tepat, sangat berpotensi digunakan sebagai alat bantu diagnosis dini di bidang kardiologi.

4. KESIMPULAN

Penelitian ini mengembangkan model klasifikasi aritmia dari sinyal EKG dengan metode SVM berbasis kernel RBF untuk mengelompokkan kondisi jantung lansia menjadi normal, abnormal, berpotensi aritmia, dan sangat berpotensi aritmia. Proses klasifikasi didahului oleh tahapan penting berupa preprocessing sinyal EKG untuk menghilangkan noise dan gangguan baseline, serta ekstraksi fitur fisiologis yang merepresentasikan aktivitas listrik jantung secara objektif. Seluruh fitur yang diekstraksi, seperti interval PR, durasi QRS, interval QT, dan heart rate, telah melalui proses validasi medis dan pelabelan oleh dokter spesialis jantung guna memastikan keakuratan klasifikasi. Evaluasi performa model menunjukkan hasil yang sangat memuaskan, dengan akurasi pada data pelatihan sebesar 96,36% dan akurasi pada data pengujian sebesar 94,57%. Selain itu, nilai AUC yang tinggi (hingga 1.00) menunjukkan kemampuan diskriminatif model yang sangat baik dalam membedakan antar kelas aritmia. Hasil ini membuktikan bahwa pendekatan SVM sangat cocok digunakan untuk klasifikasi sinyal EKG, terutama pada kelompok risiko tinggi seperti lansia. Namun, penelitian ini memiliki sejumlah keterbatasan, seperti jumlah dataset yang masih relatif terbatas dan keterbatasan variasi kondisi pasien.

REFERENCES

- [1] Chandra, A., & Suwanto, D., "Tren Kematian akibat Penyakit Jantung di Indonesia," *Jurnal Kesehatan Masyarakat Indonesia*, vol. 9, no. 2, pp. 123–130, 2021.
- [2] Damayanti, F., & Nur, M., "Aritmia pada Lansia: Kajian Patofisiologi dan Tantangan Diagnosis," *Jurnal Kardiologi Indonesia*, vol. 6, no. 1, pp. 45–52, 2024.
- [3] Kevin, K., *Dasar-Dasar Elektrokardiografi Klinis*, Jakarta: Penerbit Medika, 2022.
- [4] Rospia, A., Hartono, L., & Andika, Y., "Perubahan Anatomi Jantung pada Lansia," *Jurnal Geriatri dan Gerontologi*, vol. 3, no. 2, pp. 66–72, 2022.
- [5] Candrawati, T., & Sukraandini, M., "Komorbiditas dan Risiko Aritmia," *Jurnal Ilmu Kedokteran Klinik*, vol. 4, no. 3, pp. 88–95, 2022.
- [6] Yosephine, A., & Ratnadewi, N., "Analisis Fungsi EKG dalam Deteksi Awal Penyakit Jantung," *Jurnal Kesehatan Elektromedis*, vol. 5, no. 1, pp. 33–39, 2021.
- [7] J. Nandanwar, J. Singh, S. Choudhar, and M. Patidar, "ECG Signals- Early detection of Arrhythmia using Machine Learning approaches," *Confluence: The Journal of Graduate Liberal Studies*, Jan. 2023
- [8] Hissa, A., Rachman, T., & Sasongko, E., "Penggunaan Smart Holter 5-Lead untuk Pemantauan Jantung Lanjut Usia," *Seminar Nasional Teknologi Kesehatan*, pp. 115–121, 2024.
- [9] J. Nandanwar, J. Singh, S. Choudhar, and M. Patidar, "ECG Signals- Early detection of Arrhythmia using Machine Learning approaches," *Confluence: The Journal of Graduate Liberal Studies*, Jan. 2023.
- [10] Rustandi, R., Suhaedi, H., & Pemasari, A., "Penerapan Algoritma SVM untuk Diagnosis Penyakit Jantung," *Jurnal Sistem Informasi Medis*, vol. 7, no. 4, pp. 301–309, 2023.
- [11] Zuriel, M., & Fahrurrozi, F., "Perbandingan Kernel SVM dalam Klasifikasi Sinyal Kesehatan," *Jurnal Teknologi Informasi dan Komputer*, vol. 9, no. 3, pp. 205–213, 2021.
- [12] Ayuni, Q., Wihandika, R. C., & Yudistira, N., "Klasifikasi Aritmia dari Hasil Elektrokardiogram Menggunakan Metode Support Vector Machine," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 6, pp. 2163–2170, 2021.
- [13] Nugraha, D. T., Arifin, M. Z., & Sari, L. D., "Efek Transformasi Wavelet Diskrit pada Klasifikasi Aritmia dari Data Elektrokardiogram Menggunakan Machine Learning," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 2, pp. 112–120, 2023.
- [14] Mardhiah, A., Yulianti, D., & Hidayat, R., "Hubungan Status Gizi, Aktivitas Fisik, dan Multimorbiditas terhadap Penurunan Curah Jantung pada Pasien Cardiovascular Disease," *Jurnal Kesehatan*, vol. 12, no. 1, pp. 25–32, 2024.
- [15] M. Ojha, "Automatic detection of arrhythmias from an ECG signal using an auto-encoder and SVM classifier," *Physical and Engineering Sciences in Medicine*, Mar. 2022
- [16] Putra, B. W., Rahayu, S., & Wijaya, M., "Klasifikasi Aritmia pada Sinyal EKG Menggunakan Deep Neural Network," *Jurnal Penelitian Ilmu dan Teknologi Komputer*, vol. 13, no. 1, pp. 54–63, 2021.
- [17] Hapsari, T. R., Sukmarini, L., & Herawati, T., "Deteksi Penyakit Kardiovaskular pada Isyarat EKG Berbasis Deep Learning," *Jurnal Teknologi dan Informatika (JOTING)*, vol. 5, no. 1, pp. 1376–1383, 2023.
- [18] K. B et al., "An Innovative Machine Learning Approach for Classifying ECG Signals in Healthcare Devices," *Journal of Healthcare Engineering*, Apr. 2022,
- [19] S. Hasan, T. Pantha, and M. A. Arafat, "Design and development of a cost-effective portable IoT enabled multi-channel physiological signal monitoring system," *Biomedical Engineering Advances*, vol. 7, 100124, 2024.
- [20] Z. C. Oleiwi, E. Alshemmary, and S. H. M. Al-Augby, "Heart Disease Diagnosis System Using Multi-Methods Machine Learning," *Int. J. Electr. Comput. Eng.*, vol. 13, no. 1, pp. 45–54, 2023.
- [21] P. S. Madhulika and N. Sampath, "An Application of Normalizer Free Neural Networks on the SVHN Dataset," May 2022
- [22] Pratama, A. R., Suryani, N., & Gunawan, A., "Implementasi Sistem Pendeteksi Premature Ventricular Contraction (PVC) Aritmia Menggunakan Metode SVM," *Jurnal Sistem Informasi dan Informatika*, vol. 6, no. 1, pp. 75–84, 2021.
- [23] Undang-Undang Republik Indonesia Nomor 13 Tahun 1998 tentang Kesejahteraan Lansia, Jakarta: Sekretariat Negara, 1998.
- [24] World Health Organization, *Cardiovascular Diseases Fact Sheet*, 2021. [Online]. Available: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))