

Deteksi Aritmia pada Lansia Menggunakan Algoritma Naive Bayes dengan Data Elektrokardiogram

Silva Armando Sudana^{*1}, Wilbram Wardana Siahaan², Terkelin Cornelius H. Tarigan³, Zolla Fauzan Pulungan⁴, Agung Prabowo⁵

^{1,2,3,4}Fakultas Teknik Informatika, Universitas Prima Indonesia

Email: ¹Silvasudana05@gmail.com, ²Wilbramwardanasiahaan@gmail.com,
³Terkelincornel@gmail.com, ⁴zollapulungan@gmail.com, ⁵agungprabowo@unprimdn.ac.id

Abstrak

Aritmia adalah gangguan irama jantung yang sering terjadi pada lansia dan dapat meningkatkan risiko kejadian kardiovaskular. Deteksi manual aritmia menggunakan Elektrokardiogram (EKG) memiliki keterbatasan dalam efisiensi dan akurasi, terutama di fasilitas kesehatan dengan sumber daya terbatas. Untuk mengatasi ini, penelitian ini bertujuan mengembangkan sistem identifikasi aritmia otomatis. Sistem ini menggunakan algoritma Naive Bayes berdasarkan data EKG dari 102 subjek lansia. Data diproses melalui beberapa tahap pra-pemrosesan, seperti imputasi rata-rata, feature scaling, dan pembagian data latih-uji dengan rasio 70:30. Model yang dihasilkan menunjukkan performa yang menjanjikan, berhasil mencapai akurasi sebesar 96% dengan F1-score rata-rata 0.97. Meskipun performa model sangat baik pada kelas mayoritas seperti "Normal" dan "Sangat Berpotensi Aritmia", recall pada kelas minoritas ("Abnormal") masih rendah karena ketidakseimbangan data. Namun, hasil penelitian ini menunjukkan bahwa pendekatan berbasis machine learning dapat menjadi solusi alternatif yang efektif untuk mendukung diagnosis awal aritmia secara cepat dan objektif, terutama dalam konteks layanan kesehatan primer yang membutuhkan efisiensi tinggi.

Kata Kunci : Aritmia Lansia, EKG, Identifikasi Aritmia, Klasifikasi Multikelas, Machine Learning, Naive Bayes

Arrhythmia Detection in the Elderly Using the Naive Bayes Algorithm with Electrocardiogram Data

Abstract

Arrhythmia is a heart rhythm disorder common in the elderly, which can increase the risk of cardiovascular events. Manually detecting arrhythmia using an Electrocardiogram (ECG) has limitations in terms of efficiency and accuracy, especially in healthcare facilities with limited resources. To address this, this research aimed to develop an automated arrhythmia identification system. This system uses the Naive Bayes algorithm based on ECG data from 102 elderly subjects. The data underwent several pre-processing stages, including mean imputation, feature scaling, and a 70:30 train-test data split. The resulting model showed promising performance, achieving an accuracy of 96% with an average F1-score of 0.97. Although the model performed very well on majority classes like "Normal" and "Highly Potential Arrhythmia," the recall for the minority class ("Abnormal") remained low due to data imbalance. Nevertheless, these research findings indicate that a machine learning-based approach can be an effective alternative solution to support rapid and objective early arrhythmia diagnosis, particularly in primary healthcare settings that require high efficiency.

Keywords : Arrhythmia Identification, Electrocardiogram (ECG), Elderly Arrhythmia, Machine Learning, Multiclass Classification, Naive Bayes.

1. PENDAHULUAN

1.1. Latar Belakang

Aritmia adalah gangguan pada ritme atau laju detak jantung yang dapat menyebabkan jantung berdetak terlalu cepat (takikardia), lambat (bradikardia), atau tidak teratur, yang dapat mengganggu kemampuan jantung dalam memompa darah ke seluruh tubuh. Kondisi ini disebabkan oleh gangguan pembentukan atau penghantaran impuls listrik di jantung dan bisa menjadi kondisi yang serius hingga mengancam nyawa jika tidak ditangani dengan tepat.[1]

Aritmia jantung merupakan istilah umum yang digunakan untuk menggambarkan segala jenis gangguan irama jantung yang menyimpang dari ritme sinus normal. Aritmia terbagi menjadi dua kelompok utama, yaitu takiaritmia, di mana jantung berdetak lebih cepat dari biasanya, serta bradiaritmia, di mana detak jantung lebih lambat dari keadaan normal. Gangguan ini kerap tidak disadari oleh penderitanya karena pada beberapa kasus tidak menimbulkan gejala apa pun, sehingga baru terdeteksi saat dilakukan pemeriksaan jantung secara medis.[2]

Lanjut usia (lansia) adalah individu yang berusia 60 tahun ke atas. WHO mengklasifikasikan usia lanjut menjadi beberapa kategori: 45–59 tahun (*middle age*), 60–74 tahun (*elderly*), 75–90 tahun (*old*), dan di atas 90 tahun (*very old*). Dengan bertambahnya usia, risiko penyakit degeneratif meningkat, termasuk hipertensi, diabetes, dan penyakit jantung yang sering kali menjadi faktor pencetus aritmia.[3][4]

Elektrokardiogram (EKG) merupakan alat medis yang digunakan untuk merekam aktivitas listrik jantung dan menjadi dasar dalam diagnosis gangguan fungsi jantung, termasuk aritmia.[5] Kemampuan tenaga medis dalam merekam dan menginterpretasi EKG sangat penting untuk mencegah komplikasi jantung dan mengurangi angka kematian akibat gangguan jantung.[6]

Namun, aksesibilitas EKG bagi lansia masih terbatas karena keterbatasan mobilitas, fasilitas transportasi, biaya, serta ketersediaan tenaga ahli untuk operasi dan interpretasi hasil EKG. Oleh karena itu, diperlukan teknologi pendukung seperti sistem analisis otomatis berbasis komputer untuk membantu proses diagnosis aritmia secara lebih efektif dan efisien.

Keterbatasan metode manual dalam menganalisis data EKG mendorong pengembangan metode otomatis berbasis algoritma pembelajaran mesin, salah satunya adalah Naïve Bayes, yang digunakan untuk klasifikasi data berdimensi tinggi. Algoritma ini sederhana, cepat dalam membangun model, dan menggunakan teorema Bayes untuk menghitung probabilitas kondisional. Meski memiliki asumsi bahwa semua fitur independen, algoritma ini tetap efektif dalam banyak kasus klasifikasi. Selain Naïve Bayes, metode lain seperti Decision Tree dan SVM (Support Vector Machine) juga digunakan dalam klasifikasi aritmia berbasis EKG. Namun, kedua metode tersebut memerlukan waktu pelatihan dan sumber daya komputasi yang lebih besar dibandingkan Naïve Bayes.[7]

Algoritma Naïve Bayes adalah metode pembelajaran mesin untuk klasifikasi, khususnya pada teks dengan data berdimensi tinggi, seperti analisis sentimen dan penyaringan spam. Algoritma ini dikenal karena kesederhanaan dan efektivitasnya, mampu membangun model dengan cepat, sehingga menjadi salah satu algoritma prediksi tercepat. Disebut "naïve" karena diasumsikan bahwa setiap fitur saling independen, meskipun kenyataannya mungkin tidak. Nama algoritma ini berasal dari Thomas Bayes, dengan dasar teorema Bayes yang menghitung probabilitas kondisional berdasarkan pengetahuan sebelumnya. Naïve Bayes efektif dalam membangun model dan memahami data, namun hanya mendukung atribut dengan tipe data diskrit atau yang telah didiskretisasi, tidak cocok untuk data kontinu. Semua atribut dianggap independen dan berkontribusi pada prediksi.[8]

Deteksi dini dan diagnosis akurat terhadap aritmia sangat penting untuk memberikan penanganan yang tepat waktu dan mencegah komplikasi berat seperti stroke, gagal jantung, atau kematian mendadak. Penelitian ini bertujuan untuk mengembangkan sistem identifikasi aritmia menggunakan algoritma Naïve Bayes berbasis data EKG, dengan harapan dapat meningkatkan efisiensi dan akurasi diagnosis aritmia pada lansia, serta membantu tenaga medis dalam memberikan pengobatan yang tepat. Penerapan teknologi ini diharapkan dapat mengurangi angka kematian akibat gangguan jantung dan meningkatkan kualitas hidup lansia secara keseluruhan. [9]

Penelitian ini bertujuan untuk mengembangkan sistem identifikasi aritmia menggunakan algoritma Naïve Bayes berbasis data EKG, dengan harapan dapat menciptakan metode yang lebih efisien dan akurat dalam mendiagnosis aritmia pada lansia. Pendekatan ini diharapkan dapat meningkatkan kualitas diagnosis dan pengobatan, serta mengurangi beban penyakit jantung pada populasi lansia. Implikasi sosial dan kesehatan dari penerapan teknologi ini di rumah sakit atau klinik sangat signifikan, karena dapat mengurangi angka kematian akibat gangguan jantung yang tidak terdiagnosis dan mempercepat proses diagnostik, memudahkan tenaga medis dalam memberikan pengobatan yang tepat, serta meningkatkan kualitas hidup lansia secara keseluruhan.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan di atas, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana kinerja algoritma Naive Bayes dalam mengidentifikasi aritmia pada lansia berdasarkan data elektrokardiogram (EKG)?
2. Sejauh mana akurasi algoritma Naive Bayes dibandingkan dengan metode lainnya dalam mendeteksi aritmia pada lansia?
3. Apa faktor-faktor yang mempengaruhi keberhasilan algoritma Naive Bayes dalam identifikasi aritmia pada lansia berdasarkan data EKG?

1.3. Tujuan dan Manfaat Penelitian

1.3.1. Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk mengevaluasi kinerja algoritma Naive Bayes dalam mengidentifikasi aritmia pada lansia berdasarkan data elektrokardiogram (EKG). Penelitian ini juga bertujuan untuk mengukur tingkat akurasi algoritma Naive Bayes dalam mendeteksi aritmia pada lansia dibandingkan dengan metode lain. Selain itu, penelitian ini berupaya mengidentifikasi faktor-faktor yang memengaruhi keberhasilan algoritma Naive Bayes dalam proses identifikasi aritmia berdasarkan data EKG.

1.3.2. Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini yaitu:

1. Manfaat di Bidang Kesehatan: Penelitian ini bertujuan untuk menciptakan sistem deteksi aritmia yang lebih akurat dan efisien menggunakan algoritma Naive Bayes, yang dapat digunakan untuk membantu tenaga medis dalam mendiagnosis aritmia pada lansia.
2. Manfaat untuk Peneliti Selanjutnya: Hasil penelitian ini dapat dijadikan referensi bagi peneliti selanjutnya yang tertarik pada pengembangan sistem otomatis untuk deteksi penyakit kardiovaskular menggunakan algoritma pembelajaran mesin, khususnya Naive Bayes dan analisis data EKG.

1.4. Batasan Masalah

Berikut ini akan diuraikan batasan masalah pada penelitian ini agar penelitian berjalan sesuai dengan perencanaan, yaitu:

1. Dataset pada penelitian ini diambil dari lansia di beberapa panti jompo di sekitaran Medan, yang terdiri dari data pasien lansia yaitu usia 60 tahun keatas berdasarkan Undang-Undang Nomor 13 Tahun 1998, Dataset yang digunakan mencakup sejumlah sampel EKG dengan berbagai jenis aritmia.
2. Algoritma yang digunakan dalam penelitian ini adalah Naive Bayes, yang diterapkan untuk mengidentifikasi jenis-jenis aritmia berdasarkan data EKG. Penelitian ini hanya fokus pada pengujian dan evaluasi kinerja Naive Bayes, tanpa membandingkan dengan algoritma lain secara mendalam.
3. Penelitian ini berfokus pada ekstraksi ciri-ciri interval utama pada sinyal EKG, meliputi interval RR, PR, QS, QTC, ST, R/S dan Heart Rate tanpa melibatkan parameter Kesehatan lain yang mungkin mempengaruhi hasil identifikasi aritmia.

1.5. Keterbaruan Penelitian

Penelitian ini memiliki keterbaruan dibandingkan dengan penelitian-penelitian sebelumnya yang relevan dengan topik, yang dapat dirangkum sebagai berikut:

1. Menurut Deo Haganta Depari (2022) dalam penelitiannya yang berjudul Perbandingan Model Decision Tree, Naive Bayes dan Random Forest untuk Prediksi Klasifikasi Penyakit Jantung Dalam kasus metode klasifikasi yang memprioritaskan kecepatan pengambilan hasil, Random Forest tidak lagi menjadi pilihan terbaik. Hal ini disebabkan oleh kebutuhan model untuk membangun sejumlah besar pohon demi mencapai akurasi tinggi, yang pada akhirnya memperpanjang waktu eksekusi. Berdasarkan hasil penelitian, Random Forest membutuhkan waktu signifikan, yaitu 69 detik dengan 1000 pohon, untuk mencapai akurasi 0,75%. Sebaliknya, Decision Tree menjadi metode yang lebih optimal dalam kasus ini karena mampu mencapai akurasi sebesar 72% dengan waktu eksekusi yang jauh lebih cepat, yaitu hanya 0,118 detik.[10]
2. Menurut Rama Ayu (2023) dengan judul Penerapan Metode Naive Bayes Dalam memprediksi penyakit jantung, pengolahan data dilakukan menggunakan metode Naive Bayes dengan memanfaatkan software seperti Jupyter Notebook, Visual Studio, serta Python sebagai bahasa pemrograman. Pengujian dilakukan menggunakan tiga rasio pembagian data, yaitu 80:20, 70:30, dan 60:40. Dari ketiga metode tersebut, rasio 80:20 memberikan hasil terbaik dengan akurasi sebesar 81%. Oleh karena itu, metode Naive Bayes akan diimplementasikan dalam pengembangan aplikasi prediksi penyakit jantung..[11]
3. Menurut Muhammad Ranjasmara (2020) dengan judul Implementasi Metode Naive Bayes Dalam memprediksi risiko penyakit jantung, metode Naive Bayes digunakan untuk menguji akurasi sistem sebanyak 103 kali pengujian. Hasil tertinggi menunjukkan akurasi sebesar 92,85% dengan 70 data latih dan 70 data uji. Sementara itu, akurasi terendah adalah 87%, yang diperoleh dengan 20 data latih dan 283 data uji. Untuk penelitian di masa depan, disarankan menggunakan data dari rumah sakit di Indonesia dan menerapkan metode lain untuk kasus penyakit jantung guna mendapatkan hasil yang lebih beragam dan relevan.[12]
4. Menurut Bowo Hirwono (2023) dengan penelitian yang berjudul Implementasi Metode Naive Bayes Pada klasifikasi penderita penyakit jantung, hasil penelitian menunjukkan bahwa metode Naive Bayes mencapai

akurasi tertinggi sebesar 86,84%. Angka ini secara signifikan lebih tinggi dibandingkan dengan penelitian sebelumnya yang hanya mencapai akurasi sebesar 79,88%. Temuan ini mengindikasikan bahwa penerapan algoritma Naïve Bayes dalam penelitian ini menunjukkan performa yang cukup baik untuk pengklasifikasian kasus penyakit jantung.[13]

5. Menurut Duwi Cahya Putri Buani (2021) dengan penelitian yang berjudul Penerapan Algoritma Naïve Bayes Penggunaan seleksi fitur dengan algoritma genetika untuk prediksi gagal jantung membuktikan bahwa performa Naïve Bayes dapat meningkat secara signifikan jika proses seleksi fitur dilakukan terlebih dahulu. Dengan data yang sama, tanpa algoritma genetika, akurasi Naïve Bayes hanya mencapai 69,60%. Namun, setelah penerapan seleksi fitur menggunakan algoritma genetika, akurasi meningkat tajam hingga mencapai 96,67%.[14]

2. METODE PENELITIAN

2.1. Jenis Penelitian

Dalam Penelitian ini menggunakan pendekatan kuantitatif, yaitu metode ilmiah yang bertujuan untuk mengembangkan model matematis atau algoritma berbasis data dalam menganalisis fenomena kesehatan, khususnya identifikasi aritmia pada lansia. Pendekatan ini cocok digunakan karena penelitian ini melibatkan pengolahan data numerik EKG (Elektrokardiogram) untuk dilakukan klasifikasi jenis aritmia menggunakan algoritma Naïve Bayes.

2.2. Lokasi dan Waktu Penelitian

Penelitian ini dilaksanakan pada bulan Januari 2025 di panti jompo harapan jaya marelan, panti jompo guna budi bakti martubung, taman bodhi asri binjai. Jadwal penelitian akan dilakukan seperti berikut (Lihat Tabel 1).

Tabel 1 Jadwal penelitian yang dilakukan

Kegiatan	Bulan						
	Januari	Februari	Maret	April	Mei	Juni	Juli
1 Diskusi Topik Penelitian							
2 Pencarian Jurnal							
3 Pengumpulan Data							
4 Pembuatan Proposal							
5 Diskusi Proposal							
6 Pembuatan Aplikasi							
7 Pembuatan Laporan							
8 Publikasi Jurnal							
9 Diseminasi							

2.3. Alat dan Dataset

2.3.1 Alat

Alat dan bahan yang digunakan dalam penelitian ini sebagai berikut (Lihat Tabel 2).

Tabel 2. Spesifikasi Laptop

No	Spesifikasi	Laptop
1	Tipe	MSI GF 63
2	Prosesor	11th Gen Intel(R) Core(TM) i7-11800H
3	RAM	8GB
4	Media Penyimpanan	SSD 512GB
5	Kartu Grafis	NVIDIA Geforce RTX 3050
6	EKG	Perangkat EKG portabel

2.3.2. Dataset

Dataset Data yang digunakan berasal dari hasil rekaman EKG pasien lansia yang dikumpulkan langsung dari beberapa panti jompo di wilayah Medan. Subjek penelitian dibatasi pada individu berusia di atas 60 tahun, sesuai definisi lansia menurut Undang-Undang Nomor 13 Tahun 1998. Total dataset yang dikumpulkan terdiri dari 102 sampel data.

Fitur utama yang diekstraksi dari sinyal EKG meliputi:

- Interval RR
- Interval PR
- Interval QS
- Interval QTc
- Interval ST
- Rasio R/S
- Heart Rate (detak jantung per menit)

2.4. Pra-Pemrosesan Data

Sebelum data dimasukkan ke dalam model pembelajaran mesin, dilakukan beberapa tahap pra-pemrosesan agar data siap dianalisis.

1. Imputasi Missing Values

Untuk menangani data yang hilang, digunakan metode imputasi nilai rata-rata (mean imputation). Nilai-nilai yang hilang pada suatu fitur diganti dengan rata-rata dari fitur tersebut:

$$x_{\text{baru}} = \begin{cases} x_{\text{asli}}, & \text{jika tidak missing} \\ \mu_x, & \text{jika missing} \end{cases} \quad (1)$$

Pada persamaan (1), di mana μ_x adalah rata-rata dari fitur x

2. Standardisasi Fitur (Standard Scaler)

Agar semua fitur memiliki skala yang setara, dilakukan proses standardisasi menggunakan rumus:

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

Pada persamaan (2), dimana:

- x : nilai asli fitur
- μ : rata-rata fitur
- σ : standar deviasi fitur

Tujuan dari standardisasi adalah mencegah dominasi fitur dengan rentang nilai besar dan meningkatkan performa algoritma klasifikasi.

2.5. Model dan Evaluasi

Pengembangan sistem identifikasi aritmia otomatis dalam penelitian ini berfokus pada penerapan algoritma Naive Bayes. Pemilihan Naive Bayes didasarkan pada keunggulannya dalam kesederhanaan, kecepatan pembangunan model, dan efektivitasnya dalam klasifikasi data berdimensi tinggi, terutama dibandingkan dengan metode seperti Decision Tree dan SVM yang membutuhkan waktu pelatihan dan sumber daya komputasi lebih besar. Data EKG dari 102 subjek lansia telah melalui tahap pra-pemrosesan yang meliputi imputasi rata-rata untuk menangani nilai hilang dan feature scaling (Standard Scaler) untuk menyeragamkan rentang fitur (Interval RR, PR, QS, QTC, ST, R/S, dan Heart Rate). Pembagian data dilakukan dengan rasio latih-uji 70:30, sesuai praktik umum. Model Naive Bayes yang dikembangkan menunjukkan performa yang kuat dengan akurasi mencapai 96% dan F1-score rata-rata 0.97. Capaian akurasi ini sangat kompetitif dan melampaui hasil banyak penelitian sebelumnya yang menggunakan Naive Bayes untuk prediksi penyakit jantung. Meskipun demikian, observasi kritis menunjukkan bahwa performa model, khususnya recall, pada kelas minoritas ("Abnormal") masih rendah akibat ketidakseimbangan data dalam dataset. Hal ini menandakan adanya potensi peningkatan lebih lanjut dalam penanganan kelas minoritas. Secara keseluruhan, hasil ini tetap menggarisbawahi potensi besar pendekatan

machine learning untuk diagnosis awal aritmia yang cepat dan objektif pada lansia, mendukung tujuan penelitian untuk meningkatkan efisiensi dan akurasi diagnosis di layanan kesehatan primer.

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan dan Pembersihan Data

Pada tahap awal penelitian ini, sumber data yang digunakan berasal dari kumpulan rekaman medis berupa file bernama SUBJEK_HasilOlahData.csv. File tersebut memuat informasi mengenai pengukuran denyut jantung atau heart rate dari sejumlah individu yang termasuk dalam kelompok lanjut usia. Data ini menjadi dasar utama untuk melakukan analisis lebih lanjut, termasuk proses klasifikasi kondisi aritmia.

Tabel 2 table data aritmia pada lansia

No	rr	pr	qrs	qt	qtc	st	r/s ratio	bpm	output
1	798.9899	110.1928	69.69697	267.2176	298.9472	164.9832	2.494625	75.09482	3
2	966.25	156.25	64.28571	237.5	241.6122	148	4.393031	62.09573	3
3	789.0011	145.202	69.44444	200.7576	226.0129	111.1111	2.206854	76.04552	3
4	671.3287	108.7801	80.80808	183.3722	223.803	71.42857	0.841933	89.375	0
5	513.4549	85.50347	49.63235	187.066	261.062	113.0757	0.757795	116.8555	1
...	...	...	...	...	...	...	...	...	...
98	713.8047	127.4281	54.7138	182.5952	216.1223	83.83838	5.266245	84.0566	3
99	681.6694	110.4746	70.92199	194.7627	235.8951	104.7463	4.597474	88.01921	3
100	848.4848	142.4242	78.56341	239.3939	259.8909	89.07254	1.712954	70.71429	0
101	691.9192	118.6869	56.01469	246.633	296.4992	158.5082	1.346861	86.71533	3
102	701.1785	104.3771	80.80808	205.3872	245.2783	107.2261	2.802897	85.57023	3

Menyajikan data EKG dari 102 individu lansia (Lihat Tabel 3), dengan setiap baris merepresentasikan data satu pasien dan kolom-kolomnya merinci berbagai parameter EKG seperti interval gelombang (rr, pr, qrs, qt, qtc, st), rasio r/s, serta detak jantung (bpm). Kolom "output" kemungkinan besar mengklasifikasikan jenis atau tingkat keparahan aritmia yang terdeteksi, di mana nilai-nilai seperti 0, 1, dan 3 merepresentasikan kategori yang berbeda, memberikan gambaran singkat mengenai kondisi jantung masing-masing lansia.

Sebelum dapat digunakan dalam proses analisis maupun pemodelan, data yang diperoleh perlu melalui tahap pra-pemrosesan guna memastikan bahwa seluruh informasi yang tersedia memiliki format yang sesuai dan siap diproses. Salah satu tantangan utama yang ditemukan pada data awal adalah adanya karakter titik (.) sebagai pemisah ribuan pada nilai numerik. Hal ini menyebabkan nilai-nilai tersebut tidak langsung dapat dibaca sebagai angka oleh program, karena tipe data yang dimiliki adalah string atau object. Untuk mengatasi masalah tersebut, dilakukan proses pembersihan data dengan menggunakan bantuan library pandas dalam bahasa Python. Tahapan awal dimulai dengan membaca file CSV, kemudian dilakukan pemeriksaan struktur data, termasuk nama kolom dan tipe data masing-masing variabel. Dari hasil pemeriksaan awal, diketahui bahwa kolom-kolom ini masih memiliki tipe data object, sehingga perlu dikonversi ke bentuk numerik agar bisa digunakan dalam analisis statistik maupun pelatihan model. Proses konversi dilakukan dengan langkah-langkah yang sistematis. Pertama, semua karakter non-numerik seperti titik dihapus menggunakan fungsi `.str.replace()`. Setelah itu, nilai yang telah dibersihkan kemudian diubah menjadi tipe data float agar dapat digunakan dalam berbagai operasi matematika maupun visualisasi. Agar proses ini tetap aman dan tidak menimbulkan error akibat entri yang tidak valid, dilakukan validasi tambahan untuk memastikan bahwa semua baris data berhasil dikonversi dengan benar. Setelah proses pembersihan selesai, dilakukan pemeriksaan ulang terhadap distribusi nilai dan statistik deskriptif untuk memastikan bahwa tidak ada nilai ekstrem yang tidak realistis atau data yang tidak relevan. Hasil akhir dari tahapan ini kemudian disimpan dalam file baru, yang akan digunakan sebagai dasar untuk tahapan selanjutnya, yaitu proses klasifikasi, analisis visualisasi, dan pembangunan model prediksi.

Melalui proses pra-pemrosesan dan pembersihan data yang teliti ini, diharapkan data yang digunakan dalam penelitian memiliki kualitas yang tinggi, sehingga dapat memberikan hasil analisis yang akurat dan dapat diandalkan. Selain itu, tahapan ini juga bertujuan untuk menghindari potensi kesalahan atau bias yang mungkin timbul akibat ketidaksinkronan format data atau adanya nilai yang tidak sesuai dengan konteks penelitian.

3.2. Klasifikasi Data Aritmia

Pada tahap ini dilakukan proses klasifikasi terhadap data denyut jantung (heart rate) subjek lanjut usia dengan tujuan mengidentifikasi kondisi fisiologis masing-masing subjek berdasarkan pola irama jantungnya. Proses klasifikasi ini sangat penting sebagai bagian dari pra-pemrosesan data sebelum membangun model prediksi menggunakan algoritma machine learning. Hasil dari klasifikasi akan digunakan sebagai label target dalam pembentukan model klasifikasi berbasis Naive Bayes.

Klasifikasi dilakukan dengan membagi rentang nilai heart rate ke dalam empat kategori utama, yaitu:

Tabel 3. Klasifikasi Rentang Nilai

Parameter	Normal	Abnormal	Berpotensi Aritmia	Sangat Berpotensi Aritmia
RR (ms)	600-1000	<600	600-1000	600-1000
PR (ms)	120-200	<120	190-200	>200
QRS (ms)	60-100	<60	101-120	>120
QT (ms)	350-440	<350	441-460	>460
ST (ms)	80-120	<80	120-130	>130
BPM	60-100	<60	101-110	>111
Rasio R/S	<1	≥ 1	≥ 1	≥ 1

Kategori ini didasarkan pada standar medis global yang dikeluarkan oleh lembaga seperti American Heart Association (AHA) dan European Society of Cardiology (ESC), serta telah disesuaikan dengan konteks deteksi awal aritmia pada populasi lanjut usia (Lihat Tabel 4).

Penjelasan Setiap Kategori:

- RR Interval : Mengukur jarak antara dua gelombang R berturut-turut. Rentang normalnya 600–1000 ms. Jika di bawah 600 ms, hasil dianggap abnormal, sementara pada rentang normal yang sama dapat menunjukkan potensi aritmia jika dikombinasikan dengan parameter lain.
- PR Interval : Menunjukkan waktu hantaran listrik dari atrium ke ventrikel. Normal berada di 120–200 ms. Di bawah 120 ms dianggap abnormal, 190–200 ms berpotensi aritmia, dan di atas 200 ms sangat berpotensi aritmia.
- QRS Duration : Menggambarkan durasi aktivasi ventrikel. Rentang normal 60–100 ms. Di bawah 60 ms dianggap abnormal, 101–120 ms berpotensi aritmia, dan di atas 120 ms sangat berpotensi aritmia.
- QT Interval : Mengukur total waktu kontraksi dan relaksasi ventrikel. Rentang normal 350–440 ms. Di bawah 350 ms dianggap abnormal, 441–460 ms berpotensi aritmia, dan di atas 460 ms sangat berpotensi aritmia.
- ST Segment : Periode setelah depolarisasi ventrikel selesai. Rentang normal 80–120 ms. Di bawah 80 ms dianggap abnormal, 120–130 ms berpotensi aritmia, dan di atas 130 ms sangat berpotensi aritmia.
- BPM (Heart Rate) : Menunjukkan detak jantung per menit. Rentang normal 60–100 bpm. Di bawah 60 bpm dianggap abnormal, 101–110 bpm berpotensi aritmia, dan di atas 111 bpm sangat berpotensi aritmia.
- Rasio R/S : Perbandingan amplitudo gelombang R dan S. Nilai <1 dianggap normal, sedangkan nilai ≥ 1 termasuk dalam kategori abnormal, berpotensi aritmia, atau sangat berpotensi aritmia tergantung parameter lainnya. [15]

3.3. Visualisasi dan Pemodelan Klasifikasi Data Aritmia

Untuk memahami karakteristik data secara lebih mendalam, dilakukan serangkaian proses eksplorasi dan pemodelan, yaitu:


3.3.1. Visualisasi Distribusi Heart Rate

Sebagai langkah awal, dilakukan visualisasi distribusi nilai heart rate berdasarkan kategori aritmia menggunakan dua pendekatan utama:

- Histogram untuk mengetahui frekuensi kemunculan tiap nilai denyut jantung dalam setiap kelas.
- Boxplot untuk melihat persebaran data serta mendeteksi adanya outlier dalam tiap kategori.

Hasil visualisasi menunjukkan bahwa sebagian besar subjek berada dalam kategori "Normal", sedangkan jumlah observasi pada kelas lainnya seperti "Abnormal", "Berpotensi Aritmia", dan "Sangat Berpotensi Aritmia" relatif lebih sedikit. Hal ini mengindikasikan adanya ketidakseimbangan kelas (class imbalance), yang perlu diperhatikan karena dapat memengaruhi kemampuan model dalam memprediksi kelas minoritas.

Histogram dengan KDE (Kernel Density Estimation) membantu memvisualisasikan pola distribusi heart rate tiap kategori, sehingga dapat dianalisis apakah data memiliki tren yang konsisten atau cenderung tersebar tidak teratur. Boxplot juga memberikan informasi tambahan berupa median, rentang interkuartil (IQR), serta indikasi outlier yang bisa menjadi data ekstrem atau anomali dalam pengukuran. Hasil visualisasi ini menjadi dasar penting dalam mengevaluasi kualitas data sebelum dilanjutkan ke proses pemodelan.



Gambar 1 Grafiik Distribusi BPM Berdasarkan Label Aritmia

Perbandingan kedua plot secara jelas menunjukkan efektivitas proses normalisasi (khususnya standardization) dalam menyeragamkan skala dan lokasi distribusi fitur (Lihat Gambar 1). Ini adalah langkah yang sangat penting dalam pipeline machine learning, karena:

1. Meningkatkan Kinerja Model: Algoritma seperti Naive Bayes (meskipun kurang sensitif terhadap skala fitur dibandingkan model berbasis jarak, tetapi tetap dapat terpengaruh oleh asumsi Gaussian untuk fitur kontinu yang sering diaplikasikan dalam Naive Bayes Gaussian), atau model lain yang mungkin dipertimbangkan, akan mendapatkan manfaat dari fitur-fitur yang terukur secara seragam.
2. Mencegah Dominasi Fitur: Fitur dengan nilai yang lebih besar tidak lagi secara otomatis memiliki bobot yang lebih tinggi dalam perhitungan model.
3. Mempercepat Konvergensi: Untuk algoritma yang melibatkan optimasi berbasis gradien, normalisasi dapat mempercepat proses konvergensi.

Secara keseluruhan, visualisasi ini mengkonfirmasi bahwa tahap pra-pemrosesan feature scaling telah berhasil dilakukan dan merupakan praktik terbaik untuk menyiapkan data EKG bagi model machine learning

3.3.2 Pemodelan Klasifikasi dengan Naive Bayes


Setelah data diolah dan dibagi menjadi fitur dan label, dibangun model klasifikasi menggunakan algoritma Naive Bayes, salah satu metode probabilistik yang efektif digunakan dalam kasus klasifikasi multikelas seperti ini. Data dibagi menjadi data latih dan data uji dengan rasio 70:30. Sebelum pelatihan model dilakukan, semua fitur distandarisasi menggunakan StandardScaler agar semua variabel berada dalam skala yang sama dan tidak ada bias akibat variasi magnitudo. Model berhasil mencapai akurasi sebesar 96% pada data uji. Hasil evaluasi lebih lanjut menggunakan classification report menunjukkan bahwa: Precision, recall, dan F1-score untuk kelas mayoritas seperti "Normal" dan "Sangat berpotensi aritmia" berada di tingkat yang tinggi. Namun, untuk kelas minoritas seperti "Abnormal", nilai recall cenderung lebih rendah, yang menunjukkan bahwa model kurang sensitif dalam mendeteksi kelas tersebut. Hal ini sangat wajar terjadi karena jumlah data pada kelas "Abnormal" jauh lebih sedikit dibandingkan kelas mayoritas, sehingga model cenderung memprediksi kelas mayoritas sebagai hasil utama.

$$Akurasi = \frac{\text{Jumlah Prediksi Benar (TP)}}{\text{Total Data}} \quad (3)$$

Pada persamaan (3), dari gambar confusion matrix:

- Jumlah Prediksi Benar (TP total) = 10 (kelas 0) + 9 (kelas 1) + 10 (kelas 2) = 29
- Total Data = 30

$$Akurasi = \frac{29}{30} = 0.9667 \text{ atau } 96.67\%$$



Gambar 2 Grafik Korelasi Antar Fitur

Confusion Matrix ini secara definitif menunjukkan kinerja model Naive Bayes yang sangat baik pada data uji (Lihat Gambar 2). Dari total 30 instans (10+10+10), hanya ada 1 instans yang salah diklasifikasikan. Akurasi keseluruhan model dapat dihitung sebagai $(10 + 9 + 10) / 30 = 29 / 30 \approx 0.9667$, atau sekitar 96.67%. Ini secara langsung mendukung klaim akurasi 96% yang disebutkan dalam deskripsi penelitian. Meskipun akurasi keseluruhan sangat tinggi, analisis detail per kelas menunjukkan bahwa satu-satunya area kelemahan (meskipun kecil dalam konteks total instans) terletak pada klasifikasi satu instans "Abnormal" yang keliru diprediksi sebagai "Sangat Berpotensi Aritmia". Dalam aplikasi medis, khususnya yang berkaitan dengan deteksi dini kondisi kritis, perhatian lebih lanjut perlu diberikan pada false negatives ini. Peneliti mungkin perlu mengeksplorasi teknik cost-sensitive learning, penyesuaian ambang batas klasifikasi, atau teknik resampling (misalnya oversampling pada kelas 1) untuk memastikan recall yang optimal untuk kelas "Abnormal" tanpa mengorbankan terlalu banyak precision pada kelas lain. Meskipun demikian, secara umum, model Naive Bayes ini terbukti sangat efektif untuk tugas identifikasi aritmia.


Tabel 4 klasifikasi menggunakan algoritma naïve bayes

Kelas	Precision	Recall	F1-Score	Support
0	1	1	1	10
1	1	0.9	0.95	10
2	0.91	1	0.95	10
Macro Avg	0.97	0.97	0.97	—
Weighted Avg	0.97	0.97	0.97	—
Akurasi Global	—	—	0.97	30

Hasil evaluasi kinerja model klasifikasi untuk tiga kelas (Kelas 0, 1, dan 2) menggunakan metrik precision , recall , F1-score , dan support (Lihat Tabel 5) . Model menunjukkan performa yang sangat baik dengan nilai precision , recall , dan F1-score yang tinggi pada semua kelas. Rata-rata makro dan rata-rata tertimbang masing-masing mencapai 0.97, serta akurasi global sebesar 0.97 atau 97%. Meski demikian, terdapat sedikit penurunan pada recall Kelas 1 dan precision Kelas 2, namun tidak signifikan memengaruhi kinerja keseluruhan model.

3.3.3. Confusion Matrix

Untuk mengevaluasi jenis kesalahan yang dilakukan oleh model secara lebih detail, digunakan Confusion Matrix sebagai metrik pendukung. Dari confusion matrix, terlihat bahwa model cenderung lebih mudah mengenali kelas "Normal" dan "Sangat berpotensi aritmia", ditunjukkan dengan jumlah True Positive (TP) yang tinggi pada kedua kelas tersebut. Namun, pada kelas "Abnormal", masih terdapat beberapa kasus yang gagal terdeteksi (False Negative), meskipun jumlah False Positive (FP) relatif kecil. Ini menunjukkan bahwa model jarang salah klaim subjek sehat sebagai "Abnormal", tetapi cukup rentan melewatkan kasus "Abnormal".




Gambar 3 Grafik Confusion Matrix

Confusion Matrix ini secara kuat mendukung klaim akurasi model sebesar 96% yang disebutkan sebelumnya (lihat Gambar 3). Dari total 30 instans uji (10+10+10), hanya 1 instans yang salah klasifikasi (dari kelas 1 ke kelas 2). Ini menghasilkan akurasi $(10 + 9 + 10) / (10 + 0 + 0 + 0 + 9 + 1 + 0 + 0 + 10) = 29 / 30 \approx 0.9667$, atau 96.67%. Meskipun akurasi keseluruhan sangat tinggi, analisis ini menyoroti bahwa satu-satunya kesalahan terletak pada klasifikasi kelas "Abnormal" yang dikelirukan dengan "Sangat Berpotensi Aritmia". Jika "Abnormal" adalah kelas yang membutuhkan intervensi segera dan "Sangat Berpotensi Aritmia" mungkin memerlukan pemantauan lebih lanjut, maka false negative tunggal ini perlu diperhatikan. Hal ini sangat relevan dengan pernyataan sebelumnya mengenai recall yang rendah pada kelas minoritas, karena meskipun hanya satu, dalam persentase kecil dari data uji kelas tersebut, dampaknya terhadap recall bisa signifikan. Secara umum, model Naive Bayes ini menunjukkan kemampuan diskriminasi yang sangat baik untuk sebagian besar kelas. Untuk meningkatkan kinerja pada kelas minoritas atau kasus-kasus yang rentan terhadap false negatives, strategi seperti

penyesuaian ambang batas, penggunaan biaya misklasifikasi yang tidak seimbang, atau teknik resampling (misalnya SMOTE untuk meningkatkan representasi kelas 1) dapat dipertimbangkan dalam iterasi pengembangan model selanjutnya.

3.3.4. klasifikasi multikelas menggunakan algoritma Naive Bayes



Gambar 4 Kurva ROC (Receiver Operating Characteristic)

Secara visual dan berdasarkan nilai AUC (lihat Gambar 4), model Naive Bayes menunjukkan performa yang sangat kuat dan sangat baik dalam mengklasifikasikan aritmia dari data EKG. AUC yang mendekati 1.00 untuk semua kelas, dan khususnya untuk micro-average, adalah indikator kemampuan diskriminatif yang superior. Namun, diskrepansi antara AUC yang tinggi dan recall yang rendah pada kelas minoritas (seperti "Abnormal") sebagaimana disebutkan dalam konteks masalah, menggarisbawahi pentingnya melihat berbagai metrik evaluasi dan tidak hanya terpaku pada AUC. Ini juga menunjukkan bahwa meskipun model dapat "memisahkan" kelas secara teoritis pada ambang batas yang optimal, dalam praktik implementasi dengan ambang batas tunggal, penanganan ketidakseimbangan data (misalnya dengan oversampling, undersampling, atau penyesuaian ambang batas) mungkin masih diperlukan untuk memastikan recall yang memadai pada kelas-kelas kritis yang jarang. Secara keseluruhan, grafik ini menegaskan potensi besar Naive Bayes untuk tugas identifikasi aritmia, meskipun perlu penyesuaian untuk mengoptimalkan deteksi kelas minoritas.

3.4. Implementasi Algoritma Naive Bayes

Dalam penelitian ini, algoritma Naive Bayes diterapkan untuk mengidentifikasi aritmia pada lansia berdasarkan data elektrokardiogram (EKG). Dataset yang digunakan diperoleh secara langsung dari beberapa panti jompo di wilayah Medan, dengan total sebanyak 102 data rekaman EKG dari lansia. Setiap data mencakup sinyal jantung yang direkam selama periode tertentu menggunakan perangkat EKG portabel, serta informasi dasar pasien seperti usia dan riwayat aritmia (jika ada). Proses pengolahan data dimulai dengan tahap pra-pemrosesan, yaitu pembersihan sinyal dari noise dan gangguan artefak. Selanjutnya, dilakukan ekstraksi fitur penting dari sinyal EKG, seperti interval R-R, durasi kompleks QRS, serta amplitudo gelombang P dan T, yang kemudian dijadikan parameter input untuk algoritma klasifikasi. Algoritma Naive Bayes dipilih karena kemampuannya dalam menangani klasifikasi data dengan efisiensi tinggi dan kecepatan komputasi yang baik, terutama pada dataset berukuran sedang. Dengan membagi data menjadi set pelatihan dan pengujian, model ini dilatih untuk mengenali pola-pola denyut jantung normal dan abnormal, lalu diuji untuk mengevaluasi akurasi deteksi aritmia. Hasil dari implementasi ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan dalam deteksi dini aritmia pada lansia.

3.5. Manfaat Penerapan Naive Bayes dalam Deteksi Aritmia Lansia

Penerapan algoritma Naive Bayes dalam deteksi aritmia pada lansia memberikan sejumlah manfaat. Pertama, proses identifikasi aritmia menjadi lebih cepat dan efisien dibandingkan metode manual yang membutuhkan tenaga medis terlatih. Kedua, model ini dapat digunakan sebagai sistem pendukung keputusan (Decision Support System) bagi tenaga medis dalam menentukan diagnosis awal.

Selain itu, dengan analisis data EKG yang bersifat numerik dan terstruktur, Naive Bayes mampu melakukan klasifikasi dengan tingkat akurasi yang baik meskipun bekerja dengan jumlah data yang terbatas. Hal ini sangat

bermanfaat dalam konteks rumah sakit atau puskesmas yang memiliki keterbatasan alat dan tenaga ahli. Secara keseluruhan, metode ini dapat meningkatkan kualitas layanan kesehatan lansia secara preventif maupun kuratif.

3.6. Diskusi

Hasil penelitian ini menunjukkan bahwa algoritma Naive Bayes mampu mencapai akurasi hingga 96% dalam mengklasifikasikan kondisi aritmia berdasarkan data EKG lansia.

3.6.1. Perbandingan dengan Studi Sebelumnya

Nilai akurasi 96% ini tergolong sangat tinggi dan kompetitif bila dibandingkan dengan penelitian-penelitian sebelumnya yang menggunakan algoritma Naive Bayes untuk deteksi penyakit jantung atau aritmia. Sebagai contoh, hasil ini sejalan dengan temuan oleh Duwi Cahya Putri Buani (2021) yang melaporkan akurasi hingga 96.67% pada Naive Bayes setelah proses seleksi fitur menggunakan algoritma genetika[14]. Capaian ini juga melampaui beberapa studi lain yang mendapatkan akurasi 81%, 92.85%, dan 86.84%. Performa superior ini mengindikasikan bahwa kombinasi pemilihan fitur EKG yang relevan (interval RR, PR, QS, QTC, ST, R/S, Heart Rate) dan tahapan pra-pemrosesan yang efektif (imputasi rata-rata, feature scaling) telah berhasil memaksimalkan kemampuan Naive Bayes dalam dataset lansia ini.

3.6.2. Interpretasi Kesalahan Klasifikasi (Recall Rendah pada Kelas Minoritas)

Meskipun akurasi keseluruhan sangat tinggi, penelitian ini mengidentifikasi adanya tantangan pada recall untuk kelas minoritas ("Abnormal") yang cenderung lebih rendah (0.9). Fenomena ini, yang sering terjadi dalam klasifikasi machine learning pada dataset tidak seimbang, disebabkan oleh representasi sampel yang minim untuk kelas "Abnormal" dibandingkan dengan kelas mayoritas seperti "Normal" dan "Sangat Berpotensi Aritmia". Model Naive Bayes, dalam upaya mengoptimalkan akurasi keseluruhan, cenderung lebih responsif dan akurat dalam mengidentifikasi kelas-kelas yang memiliki jumlah data lebih banyak. Konsekuensi dari recall yang lebih rendah pada kelas "Abnormal" adalah potensi false negatives, yaitu kondisi aritmia abnormal yang terlewatkan dan diklasifikasikan sebagai kondisi lain. Dalam konteks medis, false negatives untuk kondisi kritis seperti aritmia abnormal dapat memiliki implikasi yang serius terhadap kesehatan pasien. Untuk mengatasi masalah ini, penelitian lanjutan sangat disarankan untuk menerapkan teknik penanganan ketidakseimbangan data seperti oversampling (misalnya menggunakan SMOTE) atau undersampling pada kelas mayoritas, sehingga distribusi kelas menjadi lebih seimbang dan model dapat belajar fitur-fitur dari kelas minoritas secara lebih efektif.

3.6.3. Implikasi Hasil dalam Praktik Klinis

Secara klinis, hasil penelitian ini menunjukkan bahwa sistem berbasis Naive Bayes memiliki potensi besar untuk digunakan sebagai Sistem Pendukung Keputusan (SPK) dalam diagnosis awal aritmia pada populasi lansia. Kemampuan diagnosis otomatis yang cepat dan akurat sangat berharga, terutama di fasilitas kesehatan primer dengan keterbatasan sumber daya manusia dan keahlian spesialis dalam interpretasi EKG. Dengan menyediakan alat screening awal yang efisien, sistem ini dapat membantu tenaga medis non-spesialis untuk mengidentifikasi kasus-kasus berpotensi aritmia lebih dini, memungkinkan rujukan atau penanganan yang tepat waktu dan berpotensi mengurangi komplikasi serius seperti stroke, gagal jantung, atau kematian mendadak. Namun, penting untuk dicatat bahwa sistem ini idealnya berfungsi sebagai alat pendukung, bukan pengganti diagnosis oleh dokter ahli. Validasi lebih lanjut dengan dataset yang lebih besar, beragam, dan dari berbagai sumber klinis sangat diperlukan untuk meningkatkan generalisasi model dan keandalannya di berbagai setting klinis, memastikan aplikasinya aman dan efektif.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengklasifikasikan kondisi aritmia pada subjek lanjut usia berdasarkan nilai heart rate menggunakan algoritma Naive Bayes. Proses awal dimulai dari pembersihan data, di mana karakter titik sebagai pemisah ribuan dihapus dan nilai-nilainya dikonversi ke format numerik agar siap diproses lebih lanjut. Setelah itu, dilakukan klasifikasi heart rate ke dalam empat kategori, yaitu Normal, Berpotensi Aritmia, Sangat Berpotensi Aritmia, dan Abnormal, dengan rentang nilai yang disusun berdasarkan referensi medis.

Model Naive Bayes berhasil mencapai akurasi sebesar 96% pada data uji, menunjukkan kemampuan prediksi yang cukup baik. Hasil evaluasi melalui classification report dan confusion matrix juga membuktikan bahwa model cenderung lebih responsif terhadap kelas mayoritas seperti "Normal" dan "Sangat Berpotensi Aritmia", sementara pada kelas minoritas ("Abnormal") masih terdapat beberapa kesalahan prediksi, terutama False Negative, yang disebabkan oleh ketidakseimbangan jumlah data. Visualisasi distribusi heart rate dengan histogram dan boxplot

memberikan gambaran yang jelas tentang persebaran nilai denyut jantung serta adanya outlier dalam tiap kategori. Dengan demikian, dapat disimpulkan bahwa algoritma Naive Bayes sudah cukup efektif digunakan untuk deteksi dini aritmia berbasis heart rate, meskipun masih memerlukan peningkatan dalam hal penanganan ketidakseimbangan kelas dan penggunaan fitur tambahan. Kontribusi penelitian ini adalah penyediaan sistem otomatis yang dapat diintegrasikan ke dalam alat portabel EKG untuk deteksi dini aritmia di lapangan. Selain itu, penelitian ini juga memberikan gambaran tentang penerapan algoritma Naive Bayes dalam domain kesehatan jantung. Keterbatasan penelitian meliputi ketidakseimbangan kelas dan ukuran dataset yang relatif kecil. Prospek pengembangan meliputi perbandingan dengan algoritma lain (Decision Tree, SVM), integrasi dengan wearable device, serta uji validasi di lingkungan klinis nyata.

DAFTAR PUSTAKA

- [1] A. S. A. Y. Gede Agus Andika, "Tatalaksana aritmia: Fibrilasi atrial," *Medical Profession Journal of Lampung*, vol. 11, no. 3, pp. 247–252, 2021, doi: <https://doi.org/10.53089/medula.v11i3.309>.
- [2] A. Hanifa, "Sistem Pakar Untuk Mendiagnosa Penyakit Aritmia Menggunakan Certainty Factor," vol. 2, no. 1, pp. 41–48, 2021, doi: <https://doi.org/10.58794/santi.v2i1.63>.
- [3] F. Akbar, D. Darmiati, F. Arfan, and A. A. Z. Putri, "Pelatihan dan Pendampingan Kader Posyandu Lansia di Kecamatan Wonomulyo," *Jurnal Abdidas*, vol. 2, no. 2, pp. 392–397, Apr. 2021, doi: [10.31004/abdidas.v2i2.282](https://doi.org/10.31004/abdidas.v2i2.282).
- [4] R. Ariyanti, I. A. Preharsini, and B. W. Sipolio, "Edukasi Kesehatan Dalam Upaya Pencegahan dan Pengendalian Penyakit Hipertensi Pada Lansia," *To Maega : Jurnal Pengabdian Masyarakat*, vol. 3, no. 2, pp. 74–82, Jul. 2020, doi: [10.35914/tomaega.v3i2.369](https://doi.org/10.35914/tomaega.v3i2.369).
- [5] S. Wardani, D. Darliana, M. Program Studi Ilmu Keperawatan, F. Keperawatan Universitas Syiah Kuala, and B. Kelimuwan Keperawatan Medical Bedah Fakultas Keperawatan, "KOMPETENSI MAHASISWA KEPERAWATAN DALAM MENGINTERPRETASI EKG MELALUI PEMBELAJARAN DARING PADA MASA PANDEMI Competence of Nursing Students in Interpreting the ECG Through Online Learning During the Pandemic," *Idea Nursing Journal*, vol. XIII, no. 3, pp. 51–56, 2022.
- [6] R. M. Nugroho and T. Herawati, "PEREKAMAN CEPAT ELEKTROKARDIOGRAM ESOPHAGEAL ATRIAL STIMULATION INTEGRATED (EKG EASI) NIRKABEL: A LITERATURE REVIEW," 2023. doi: <https://doi.org/10.70332/jkp.v1i2.7>.
- [7] M. Nurkholifah and F. Kurnia Oktorina, "Analisa Penyakit Jantung Menggunakan Algoritma Naïve Bayes," vol. 4, no. 1, pp. 26–36, Jan. 2023, doi: <https://doi.org/10.47650/jsce.v4i1.671>.
- [8] achmad ridwan, "Penerapan Algoritma Naïve Bayes Untuk Klasifikasi Penyakit Diabetes Mellitus," vol. IV, no. 1, pp. 15–21, Sep. 2020, doi: <https://doi.org/10.47970/siskom-kb.v4i1.169>.
- [9] Y. Julia Nurrisi and Alamsyah, "Indonesian Journal of Mathematics and Natural Sciences Optimasi Deep Convolutional Neural Network (Deep CNN) untuk Deteksi Aritmia Melalui Sinyal EKG Menggunakan Arsitektur Conv1D," vol. 46, no. 1, pp. 10–20, Apr. 2023, doi: <https://doi.org/10.15294/ijmns.v46i1.46176>.
- [10] Deo Haganta Depari, Yuni Widiastiwi, and Mayanda Mega Santoni, "Perbandingan Model Decision Tree, Naive Bayes dan Random Forest untuk Prediksi Klasifikasi Penyakit Jantung," vol. 18, no. 3, pp. 239–248, Dec. 2022, doi: <https://doi.org/10.52958/iftk.v18i3.4694>.
- [11] R. Ayu, S. Maharani, S. Informasi, and S. Royal Kisaran, "PENERAPAN METODE NAÏVE BAYES DALAM MEMPREDIKSI PENYAKIT JANTUNG," *Jurnal Teknologi Komputer dan Sistem Informasi Februari*, vol. 6, no. 1, pp. 8–13, 2023, doi: <https://doi.org/10.54314/teknisi.v3i1.1252>.
- [12] M. Ranjasmara, A. Khairan, F. Tempola, and Rosihan, "Implementasi Metode Naive Bayes Untuk Memprediksi Resiko Penyakit Jantung," vol. 4, no. 2, pp. 66–70, Oct. 2020, doi: <https://doi.org/10.33857/patj.v4i2.351>.
- [13] B. Hirwono, A. Hermawan, and D. Avianto, "Implementasi Metode Naïve Bayes untuk Klasifikasi Penderita Penyakit Jantung," *Jurnal Teknologi Informasi dan Komunikasi*, vol. 7, no. 3, pp. 450–457, 2023, doi: <https://doi.org/10.35870/jtik.v7i3.910>.
- [14] D. C. P. Buani, "Penerapan Algoritma Naïve Bayes dengan Seleksi Fitur Algoritma Genetika Untuk Prediksi Gagal Jantung," *Jurnal Sains dan Manajemen*, vol. 9, no. 2, pp. 43–48, 2021, doi: <https://doi.org/10.31294/evolusi.v9i2.11141>.
- [15] American Heart Association, "About Arrhythmia," website. Accessed: May 27, 2025. [Online]. Available: <https://www.heart.org/en/health-topics/arrhythmia/about-arrhythmia>