

CLASSIFICATION OF HYPERTENSION USING KNN BASED ON PHOTOPLETHYSMOGRAPH DATA AND BLOOD PRESSURE ESTIMATOR

KLASIFIKASI HIPERTENSI MENGGUNAKAN KNN BERDASARKAN DATA PHOTOPLETHYSMOGRAPH DAN ESTIMATOR TEKANAN DARAH

Jasmin William Natanael Sinaga¹, Ester Farida Simanjuntak², Tasya Rouli Christy Tampubolon³, Delima Sitanggang⁴, Reyhan Achmad Rizal⁵

^{1,2,3,4,5} Universitas Prima Indonesia, Jl. Sampul No.3, Kota Medan, Sumatera Utara, Indonesia

email: williamkjt34@gmail.com¹, farydasimanjuntak@gmail.com², tasyachristy1907@gmail.com³, delimasitanggang@unprimdn.ac.id⁴, reyhanachmadrizal@unprimdn.ac.id⁵

Abstract - Hypertension is a chronic cardiovascular condition often referred to as the "silent killer" due to its asymptomatic early stages. To overcome the limitations of conventional blood pressure monitoring methods, this study aims to develop a blood pressure status classification system using photoplethysmography (PPG) signals and the KNN algorithm. PPG offers a promising non-invasive solution that can be integrated into portable devices to optimize real-time blood pressure monitoring. Data was collected from 276 respondents (aged 18–65 years, with 52% male and 48% female) using PPG sensors connected to the MR-IAT Robot Covid platform. The classification process is based on measuring the proximity of new sample data—using the Euclidean Distance method—to previously labelled data, with performance evaluation yielding an accuracy of 93.9% in classifying individuals into four categories: normotension, prehypertension, stage 1 hypertension, and stage 2 hypertension. This study distinguishes itself by integrating a real-time machine learning approach, offering an efficient, accurate, and user-friendly blood pressure monitoring system with the potential to enhance early detection of hypertension.

Keywords - Hypertension, Photoplethysmography, KNN, Blood Pressure Classification, Non-Invasive Monitoring.

Abstrak - Hipertensi adalah kondisi kardiovaskular kronis yang sering disebut sebagai "silent killer" karena tahap awalnya yang asimtomatik. Untuk mengatasi keterbatasan metode pemantauan tekanan darah konvensional, penelitian ini bertujuan mengembangkan sistem klasifikasi status tekanan darah dengan memanfaatkan sinyal photoplethysmography dan algoritma KNN. PPG menawarkan solusi non-invasif yang dapat diintegrasikan ke dalam perangkat portabel guna mengoptimalkan pemantauan tekanan darah secara real-time. Data dikumpulkan dari 276 responden (usia 18–65 tahun, dengan 52% pria dan 48% wanita) menggunakan sensor PPG yang terhubung ke platform MR-IAT Robot Covid. Proses klasifikasi dilakukan dengan mengukur kedekatan sampel data baru—menggunakan metode Euclidean Distance dengan data yang telah dilabel sebelumnya, dan hasil evaluasi kinerja menunjukkan akurasi sebesar 93,9% dalam mengklasifikasikan individu ke dalam empat kategori: normotensi, prehipertensi, hipertensi tahap 1, dan hipertensi tahap 2. Studi ini membedakan dirinya dengan mengintegrasikan pendekatan machine learning secara real-time, menyediakan sistem pemantauan tekanan darah yang efisien, akurat, dan ramah pengguna, sehingga berpotensi meningkatkan deteksi dini terhadap kondisi hipertensi.

Kata Kunci - Hipertensi, Photoplethysmography (PPG), KNN, Klasifikasi Tekanan Darah, Pemantauan Non-Invasif

I. PENDAHULUAN

Hipertensi merupakan salah satu faktor risiko utama gangguan kardiovaskular yang sering tidak terdeteksi pada awal penyakit, sehingga berpotensi menyebabkan komplikasi serius seperti stroke dan gagal ginjal. Zhao et al. (2023) menyebut hipertensi sebagai “silent killer” yang berkontribusi signifikan terhadap morbiditas global [1]. Islam et al. (2022) menegaskan pentingnya deteksi dini pada hipertensi guna mencegah komplikasi yang mengancam jiwa [2]. Pengukuran tekanan darah secara konvensional menggunakan manset masih menjadi standar di fasilitas klinis. Namun, metode ini memiliki keterbatasan dari segi kenyamanan dan tidak mampu melakukan monitoring kontinu. Le et al. (2020) menunjukkan bahwa keterbatasan tersebut membuat metode manset kurang ideal untuk pemantauan harian [3]. Selain itu, Sannino et al. (2020) menyoroti bahwa adanya fenomena white coat menyebabkan hasil pengukuran tidak selalu mencerminkan kondisi sebenarnya [4]. Sebagai alternatif, teknologi non-invasif berbasis sensor optik seperti Photoplethysmography (PPG) telah dikembangkan karena kemampuannya untuk menangkap perubahan volume darah secara real-time. Cano et al. (2022) menunjukkan bahwa PPG dapat mencatat variasi hemodinamik dengan efektif [5]. Andriekuté et al. (2024) menyoroti potensi integrasi PPG ke dalam perangkat wearable untuk pemantauan 24 jam [6]. Selain itu, Hong et al. (2025) mengemukakan bahwa perbedaan pola PPG antara kondisi terjaga dan tidur dapat bermanfaat untuk skrining hipertensi [7]. Namun demikian, sinyal PPG rentan terhadap gangguan seperti gerakan tubuh, varian posisi sensor, dan perbedaan kondisi fisiologis individu. Welykholowa et al. (2020) melaporkan bahwa artefak dari gerakan dapat mengaburkan sinyal dengan signifikan [8]. Liang et al. (2020) juga menekankan perlunya proses pra-pemrosesan untuk menangani variabilitas antarindividu [9]. Dalam ranah pengolahan data, model machine learning seperti SVM dan Convolutional Neural Network (CNN) banyak digunakan untuk estimasi tekanan darah. Namun, model-model kompleks ini memerlukan sumber daya komputasi tinggi yang membatasi penerapannya pada perangkat portabel [10]. Sebaliknya, K-Nearest Neighbor (KNN) menawarkan solusi yang lebih ringan dengan waktu pelatihan yang cepat serta performa yang kompetitif. Tjahjadi (2020) menunjukkan bahwa KNN mampu menghasilkan klasifikasi yang baik pada data morfologi sinyal PPG [11]. Selain itu, Gentilin (2025) mengonfirmasi bahwa model KNN tetap kompetitif jika dibandingkan dengan metode lain seperti SVM dan CNN [12]. Meskipun demikian, masih terdapat sedikit penelitian yang secara eksplisit menggabungkan sinyal PPG dengan algoritma KNN untuk mengklasifikasikan status hipertensi pada populasi yang beragam.

II. SIGNIFIKASI STUDI

A. Studi Literatur

Dalam beberapa tahun terakhir, perkembangan teknologi digital telah memunculkan potensi besar penggunaan Photoplethysmography (PPG) untuk pemantauan tekanan darah secara non-invasif. Iqbal et al. (2023) menunjukkan bahwa sinyal PPG yang diambil dari berbagai lokasi tubuh dapat membedakan kondisi vaskular secara akurat melalui penerapan pendekatan deep learning [13]. Namun, model berbasis deep learning memerlukan dataset yang sangat besar dan infrastruktur komputasi yang mahal sehingga tidak selalu ideal untuk aplikasi perangkat wearable [14]. Di sisi lain, algoritma yang ringan seperti KNN menawarkan keunggulan dari segi kecepatan dan efisiensi komputasi, terutama untuk sistem berbasis edge computing yang digunakan pada perangkat dengan daya terbatas. Gentilin (2025) melaporkan bahwa KNN mampu menghasilkan klasifikasi yang kompetitif dengan waktu pelatihan yang singkat pada data morfologi PPG. Ismail et al. (2022) juga menekankan bahwa algoritma sederhana lebih sesuai untuk diimplementasikan pada sistem monitoring berbasis mikrokontroler [15].

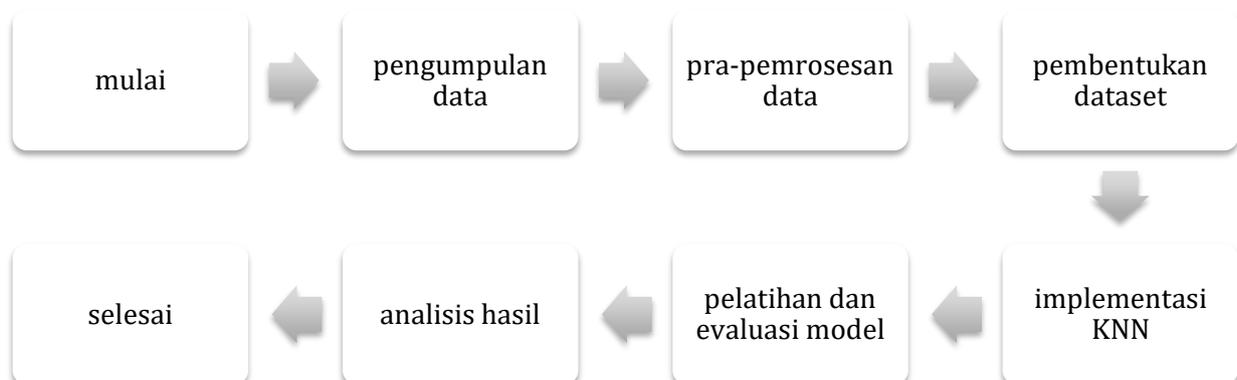
Selain pendekatan tersebut, studi-studi terbaru juga menunjukkan bahwa integrasi data multimodal dapat lebih meningkatkan akurasi klasifikasi tekanan darah. Nur Fuadah et al. (2022) mengusulkan penggabungan sinyal PPG dengan sinyal elektrokardiogram (ECG) untuk menghasilkan model klasifikasi tekanan darah yang lebih akurat, membuktikan bahwa integrasi multimodal dapat meningkatkan performa prediksi [16].

Pendekatan sistematis yang dievaluasi oleh Alam et al. (2024) menyoroti peran penting model machine learning tradisional dan alternatif dalam menginterpretasi sinyal PPG untuk estimasi parameter fisiologis. Studi ini menunjukkan bahwa meskipun model deep learning sering kali menawarkan akurasi tinggi, algoritma sederhana seperti KNN tetap memberikan kinerja yang memadai untuk aplikasi real-time karena keunggulan efisiensi komputasinya[17]. Lebih lanjut, penelitian longitudinal oleh Lin et al. (2024) menggunakan data PPG dari pergelangan tangan dan model deep learning mengungkap bahwa pola sinyal dapat dipakai untuk memprediksi risiko hipertensi dalam jangka panjang. Hasil penelitian ini menegaskan potensi pemantauan kontinu pada perangkat wearable yang dapat mendukung skrining hipertensi secara dini[18].

Sebagian besar penelitian terdahulu fokus pada estimasi numerik tekanan darah, bukan pada klasifikasi klinis yang dapat langsung diterapkan dalam pengambilan keputusan medis. Penelitian ini mengisi kekosongan tersebut dengan membangun kerangka klasifikasi yang mencakup kategori normotensi, prehipertensi, serta hipertensi tahap 1 dan 2, sehingga memudahkan interpretasi hasil di tingkat klinis.

B. Metode Penelitian

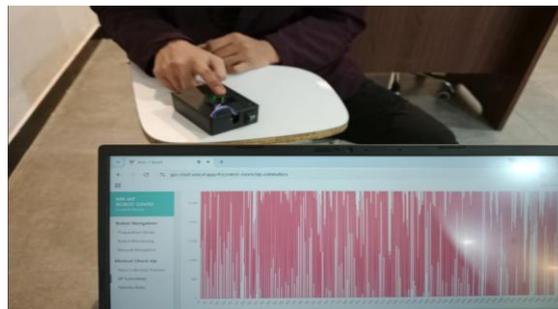
Dalam penelitian ini, kami mengimplementasikan pendekatan K-Nearest Neighbor (KNN) sebagai metode klasifikasi utama. Algoritma KNN bekerja dengan mengidentifikasi sejumlah data terdekat yang ukurannya diukur melalui jarak seperti Euclidean distance sebagai acuan untuk menentukan kelas dari data baru. Dengan demikian, setiap sampel yang belum memiliki label diklasifikasikan berdasarkan tingkat kemiripan fitur dengan data yang telah berlabel. Pendekatan ini memungkinkan kami untuk mengekstrak pola-pola penting dari data yang kompleks secara efisien dan meningkatkan akurasi prediksi, sehingga memberikan kehandalan dalam proses pengambilan keputusan berbasis data. Selain itu, fleksibilitas KNN dalam mengadaptasi terhadap variasi data menjadikannya pilihan yang tepat untuk penelitian ini, dimana setiap data dihitung tingkat kedekatannya guna menghasilkan klasifikasi yang relevan dan konsisten.



Gambar 1. Alur Penelitian

1. Pengumpulan Data

Dalam penelitian ini, pengumpulan data dilakukan di tiga lokasi strategis yaitu Universitas Prima Indonesia, SMK 2 Telkom, dan Panti Jompo di Jalan Tombak, Pancing untuk memperoleh keragaman sampel yang representatif. Eksperimen melibatkan 123 partisipan laki-laki dan 153 partisipan perempuan dengan rentang usia yang sangat bervariasi, mulai dari kurang dari 25 tahun hingga lebih dari 60 tahun. Pemilihan lokasi yang heterogen serta variasi demografis peserta ini bertujuan untuk mendapatkan gambaran menyeluruh tentang kondisi tekanan darah di berbagai lapisan masyarakat. Data yang terkumpul nantinya akan diolah dan dianalisis menggunakan teknik-teknik statistika serta algoritma pembelajaran mesin untuk mendukung pengembangan metode diagnostik hipertensi yang lebih efektif dan akurat.



Gambar 2. Proses Pengambilan Data

2. Pra-pemrosesan Data

Proses pra-pemrosesan data merupakan langkah krusial untuk memastikan data mentah siap digunakan dalam tahap pemodelan. Dalam penelitian ini, tahap tersebut mencakup beberapa fase penting. Pertama, dilakukan pembersihan data untuk menghilangkan duplikasi dan menangani nilai kosong, sehingga hanya data berkualitas tinggi yang tersimpan untuk analisis lebih lanjut. Selanjutnya, normalisasi dilakukan dengan menerapkan metode Min-Max untuk menyamakan skala semua fitur ke rentang yang konsisten, misalnya antara 0 dan 1, guna menghindari bias yang mungkin timbul akibat perbedaan skala. Terakhir, pada data yang memiliki sifat deret waktu, dilakukan transformasi dengan menyusun data secara sekuensial menggunakan teknik seperti look-back window. Pendekatan ini memungkinkan deteksi pola temporal yang lebih mendalam dan meningkatkan keandalan model dalam memahami dinamika data. Hasil dari proses pra-pemrosesan ini menjadi fondasi yang kokoh untuk tahap pemodelan dan analisis lebih lanjut.

Asmaria G	52	90				20.72103	132.9069	88.76659	77.25322	776.6667	51.61288	76.06815
Daud Puri	66	65				20.26033	134.9779	89.60443	73.75538	813.5	30.3768	53.12459
Yesi Artau	58	52				19.21979	135.3313	89.60946	88.73024	676.2069	16.27645	12.10077
Suranta B.	52	84				20.63317	134.3036	89.73208	74.78754	802.2727	46.89755	65.42171
Lubiker Sil	65	75				19.88358	141.9882	80.85342	177.69	337.6667	182.6049	313.2855
Margareth	68	55				34.43607	211.1606	114.0163	594.0594	101	104.4462	160.4046
Sahala Gu	51	55				19.24909	130.809	86.74086	82.91874	723.6	31.60759	34.7663
Martin Sin	50	65				19.28565	135.0809	90.40476	103.3295	580.6667	16.11073	15.92393
Jakson Hu	55	52				20.967	147.4255	88.46059	191.4894	313.3333	151.5109	221.148
Veronika F	53	32				18.08277	126.1917	84.43624	107.3119	559.1176	21.19484	31.57483
Efendi Siai	63	60				19.87801	130.1494	86.69021	95.89041	625.7143	57.16071	80.25999
Richard Sii	70	69				20.89629	143.6895	94.23333	68.67846	873.6364	18.71933	29.4392
Sutarman	67	72				21.62585	132.5761	88.68189	78.14761	767.7778	126.5155	136.3329
Monang G	56	62				20.40397	117.286	77.96194	91.70306	654.2857	112.4858	193.6492
Asna	65	65				22.41922	158.9882	100.8793	223.2558	268.75	106.2353	123.6932
Darwis	57	64				21.0792	136.8598	89.7116	61.88925	969.4737	38.99712	63.15765
Benyamin	59	76				20.52005	135.14	90.14503	82.56881	726.6667	51.20764	59.4291
antoni siti	50	77				16.6787	127.8715	65.60536	309.9631	193.5714	206.2802	373.2922

(a)

No	Nama	Usia	Berat Badan	Sistol	Diastol	Respirasi	Riwayat Penyakit
1	Asmina	73	58	139.2	91.3	21.4	lantung
2	Moralina Marina	76	66	134.5	89.6	20.9	-
3	Pestaria Sianturi	59	60	135.4	89	20.4	lantung
4	Binan Turnip	62	72	135.8	90.5	20.2	-
5	Sontalina Silalahi	58	64	131.6	87.8	19.9	-
6	Tiarma Sinaga	75	65	134.6	90.2	21.7	-
7	Hotinda Pesaribu	64	54	127.8	85.3	20	lantung
8	I.Turnip	67	75	151.9	98.2	22.8	lantung
9	Jonny Sihotang	56	64	128.5	86.2	21.3	-
10	Petrus Parlindungan Purba	47	80	136.2	90.4	20.5	-
11	Hotmina Hutabarat	53	78	134.1	89.2	20.1	-
12	Budiman Turnip	57	55	131.2	87.8	19.1	-
13	Slantarina Turnip	48	62	147.7	89.1	21	-
14	Gormawati Sihotang	54	62	130.9	86.7	19.9	-
15	Udur Farida Panjaitan	66	59	135.4	89.8	19.4	-
16	Termina Turnip	61	65	120.8	81.5	20.9	-
17	Atur Turnip	76	70	139.7	93.2	21.1	-
18	Dermi Sinebang	65	65	139.3	93.2	19.6	-
19	Kasuria Turnip	65	56	135.8	90.7	19.4	-
20	Lerlin Manik	53	72	140	91.4	20.4	-

(b)

Gambar 3. (a) Data Sebelum Pra-processing, (b) Data Sesudah Pra-processing

3. Pembentukan Dataset

Setelah tahap pra-pemrosesan yang meliputi pembersihan atau penghapusan duplikasi dan penanganan nilai kosong serta normalisasi atau penyamaan skala antar fitur, sinyal PPG beserta variabel pendukung seperti usia, jenis kelamin, berat badan, serta estimasi tekanan darah diintegrasikan untuk menyusun dataset yang terstruktur. Setiap baris dataset merepresentasikan satu pengamatan individual, yang kemudian diberi label berdasarkan klasifikasi tekanan darah ke dalam 6 kategori: Hipotensi, Normal, Prahipertensi, Hipertensi Stage 1, Hipertensi Stage 2, dan Hipertensi Kritis. Pengelompokan atribut ini tidak hanya menciptakan variabel target yang konsisten untuk algoritma KNN, tetapi juga memastikan setiap entri memuat informasi historis dan kontekstual yang relevan guna mendukung proses pelatihan dan validasi model klasifikasi secara akurat. Keseluruhan proses integrasi tersebut memberikan fondasi yang kuat bagi analisis data, sehingga model dapat mengenali pola dan dinamika sinyal secara optimal untuk pemantauan tekanan darah secara real-time.

	A	B	C	D	E	F	G	H	I	J
1	Jenis Kelar	Usia	Berat Bad	Sistol	Diastol	Respirasi	Klasifikasi Baru			
2	P	19	68	161	89	20.9	Hipertensi Stage 2			
3	L	19	53	234	125	39.7	Hipertensi Krisis			
4	L	21	75	118	79	18.7	Hipotensi			
5	L	40	87	137.1	91.2	20.4	Hipertensi Stage 1			
6	L	40	45	126.6	82.4	18.4	Prahipertensi			
7	L	46	58	140.7	81.9	19.7	Hipertensi Stage 1			
8	P	18	40	120	80	17.3	Normal			
9	P	18	40	120	80	17.3	Normal			
10	L	17	59	187.9	89.2	28.5	Hipertensi Krisis			
11	P	59	52	152.6	101.8	21.7	Hipertensi Stage 2			

Gambar 3. Pembentukan Dataset

4. Implementasi KNN

Implementasi KNN dilakukan dengan menerapkan algoritma klasifikasi pada dataset yang telah melalui proses pra-pemrosesan meliputi pembersihan, normalisasi, dan pembentukan dataset berbasis look-back window. Dalam tahap ini, pemilihan parameter K yakni jumlah tetangga terdekat yang dijadikan acuan memegang peranan krusial untuk menentukan klasifikasi yang tepat. Untuk setiap data baru yang hendak diklasifikasikan, digunakan rumus Euclidean distance untuk menghitung jarak antara vektor fitur data baru dengan masing-masing vektor dalam data pelatihan, sehingga data baru tersebut dikategorikan berdasarkan mayoritas kelas dari tetangga terdekatnya. Penggunaan Euclidean distance sebagai ukuran kemiripan memungkinkan algoritma ini mengidentifikasi pola secara efektif dalam data kompleks, sehingga mendukung sistem klasifikasi yang akurat untuk aplikasi pemantauan tekanan darah secara real-time. Secara matematis, rumus Euclidean distance dinyatakan sebagai:

$$dis(x_1, x_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \tag{1}$$

Dimana:

$dis(X_1, X_2)$ adalah jarak antara objek X_1 dan X_2

X_{1i} adalah nilai objek data *training* X_1 pada variabel ke i

X_{2i} adalah nilai objek data *testing* X_2 pada variabel ke i

i adalah banyaknya variabel bebas

Setelah menghitung jarak antara data baru dengan seluruh data training, ditetapkan K data dengan jarak terkecil sebagai tetangga terdekat. Kelas dari data baru kemudian ditentukan berdasarkan label mayoritas di antara K tetangga tersebut. Pendekatan ini memungkinkan algoritma KNN untuk secara efisien mengelompokkan status hipertensi ke dalam kategori. Proses tersebut memastikan bahwa setiap sampel baru diklasifikasikan sesuai dengan pola morfologi sinyal PPG yang telah terbentuk, sehingga mendukung akurasi dan konsistensi prediksi. Dengan cara ini, model tidak hanya menangkap hubungan spasial antar data, tetapi juga memberikan dasar yang kuat untuk pengembangan sistem pemantauan tekanan darah secara real-time yang andal dan responsif.

5. Pelatihan Dan Evaluasi Model

Setelah dataset terstruktur berhasil dikembangkan, tahap pelatihan dan evaluasi model dilakukan dengan mengintegrasikan dua platform utama, yaitu Google Colab dan MATLAB. Dalam proses pelatihan, algoritma KNN menerapkan perhitungan jarak di mana setiap sampel data baru dihitung jaraknya terhadap seluruh data training menggunakan rumus Euclidean lalu sampel tersebut diklasifikasikan berdasarkan mayoritas kelas dari K tetangga terdekatnya. Evaluasi model dilakukan dengan menerapkan confusion matrix dan analisis metrik akurasi, yang menunjukkan distribusi kesalahan yang minimal serta tingkat akurasi mencapai setidaknya 80%. Selain itu, hasil model divisualisasikan melalui scatter plot dua dimensi setelah reduksi fitur menggunakan Principal Component Analysis (PCA), sehingga memperlihatkan pemisahan yang jelas antar kategori hipertensi. Proses pelatihan dan evaluasi ini tidak hanya membuktikan kemampuan model dalam mengenali pola sinyal PPG secara efektif tetapi juga menyediakan dasar yang kokoh untuk pengembangan sistem pemantauan tekanan darah real-time secara non-invasif dan akurat.

6. Analisis Hasil

Setelah model KNN dilatih dan diuji, analisis menunjukkan bahwa sistem mampu mengklasifikasikan status hipertensi dengan tingkat akurasi yang tinggi. Visualisasi hasil dari kedua platform analisis memperlihatkan reduksi fitur yang menampilkan distribusi jelas antar kategori tekanan darah, sehingga mengonfirmasi efektivitas penerapan model dalam mengidentifikasi pola morfologi sinyal PPG. Pendekatan ini tidak hanya memperkuat validitas metode klasifikasi yang digunakan, tetapi juga menunjukkan potensi penerapan yang luas dalam pengembangan sistem pemantauan tekanan darah secara real-time yang andal dan non-invasif.

C. Kontribusi Unik Penelitian

Penelitian ini mengatasi beberapa keterbatasan yang diidentifikasi pada studi terdahulu, dengan memberikan solusi praktis bagi aplikasi nyata dalam pemantauan hipertensi. Secara spesifik:

1. Mengatasi Keterbatasan Sinyal PPG: – Penelitian ini menerapkan proses pra-pemrosesan yang komprehensif (pembersihan data, normalisasi Min-Max, dan teknik look-back window) untuk mengurangi dampak noise dan variabilitas yang disebabkan oleh pergerakan dan perbedaan fisiologis. Langkah-langkah ini dirancang sedemikian rupa sehingga sinyal PPG yang dihasilkan menjadi lebih stabil dan dapat diandalkan untuk klasifikasi hipertensi.
2. Adopsi Algoritma KNN untuk Aplikasi Portable: Dibandingkan dengan model deep learning yang kompleks, KNN dipilih karena kecepatan pelatihan dan efisiensi komputasinya. Hal ini memungkinkan algoritma untuk dijalankan pada perangkat dengan daya dan memori terbatas, seperti smartphone dan perangkat wearable. Hasil pengujian pada dua platform (Google Colab dan

MATLAB) menunjukkan akurasi tinggi (masing-masing 92,8% dan 93,9%), yang mendemonstrasikan bahwa algoritma ini dapat diterapkan secara real-time tanpa memerlukan infrastruktur komputasi yang berat.

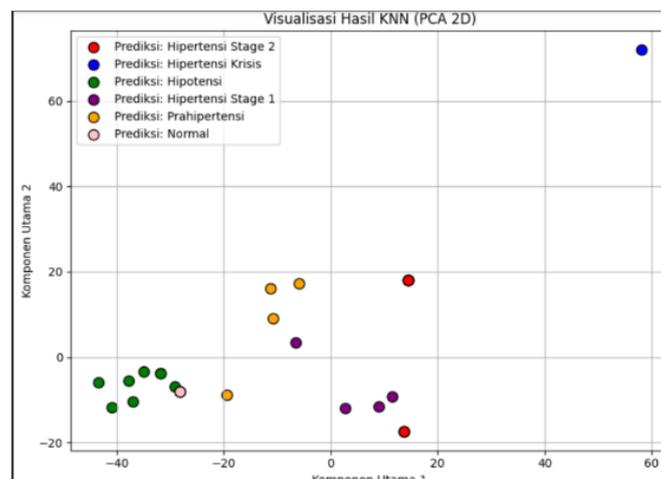
3. Penerapan Langsung pada Perangkat Wearable dan Praktik Medis: Desain sistem yang diusulkan sudah mempertimbangkan integrasi langsung ke dalam perangkat wearable. Proses pra-pemrosesan yang ringan dan algoritma KNN yang efisien menyederhanakan penggunaan perangkat keras yang terbatas, sehingga memungkinkan monitoring tekanan darah secara kontinu di luar lingkungan klinis. – Selain itu, visualisasi hasil (melalui scatter plot dan diagram koordinat paralel) memberikan gambaran yang jelas mengenai distribusi kelas hipertensi, yang memudahkan tenaga medis dalam menafsirkan data dan mengambil keputusan klinis.

Dengan demikian, kontribusi unik penelitian ini tidak hanya terletak pada penerapan teknik machine learning yang efisien untuk klasifikasi hipertensi, tetapi juga menyediakan kerangka yang siap pakai untuk integrasi langsung ke dalam perangkat wearable dan aplikasi mobile yang mendukung praktik pemantauan klinis secara real-time.

III. HASIL DAN PEMBAHASAN

A. Pengolahan Menggunakan Google Colab

Seluruh tahapan klasifikasi dilaksanakan menggunakan bahasa pemrograman Python di platform Google Colab, dengan bantuan pustaka seperti Scikit-learn. Dataset yang digunakan mencakup sinyal PPG, usia, jenis kelamin, berat badan, serta estimasi tekanan darah sistolik dan diastolik. Data ini diklasifikasikan ke dalam enam kategori tekanan darah: Hipotensi, Normal, Prahipertensi, Hipertensi Tahap 1, Hipertensi Tahap 2, dan Krisis. Setelah melalui proses encoding label dan pembagian data dengan rasio 90:10, model KNN diterapkan dengan nilai $K = 3$. Hasil klasifikasi divisualisasikan dalam scatter plot dua dimensi setelah proses reduksi dimensi menggunakan PCA. Grafik menunjukkan pemisahan kelas yang cukup baik, meskipun terdapat beberapa titik pencilan (outlier) pada kategori pra-hipertensi dan hipertensi tahap 1. Outlier ini kemungkinan disebabkan oleh gangguan pada sinyal atau variasi fisiologis seperti frekuensi nadi dan pola respirasi, yang belum sepenuhnya ditangkap oleh fitur yang dianalisis.



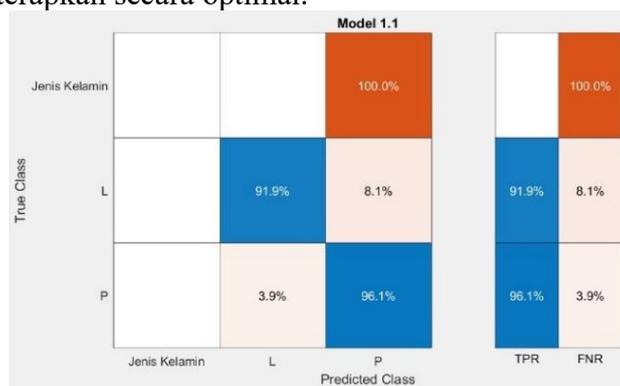
Gambar 4. Hasil Visualisasi Prediksi KNN Dalam Dua Dimensi (PCA)

B. Pengolahan Menggunakan MATLAB

Setelah proses klasifikasi dijalankan menggunakan Google Colab, tahap selanjutnya adalah melakukan analisis hasil klasifikasi dengan MATLAB. Platform MATLAB dimanfaatkan untuk analisis lanjutan dan representasi visual data. Proses visualisasi menggunakan scatter plot dan parallel coordinates plot, yang menekankan bahwa variabel usia dan berat badan memberikan kontribusi signifikan dalam klasifikasi tekanan darah.

1. Model Confusion Matrix

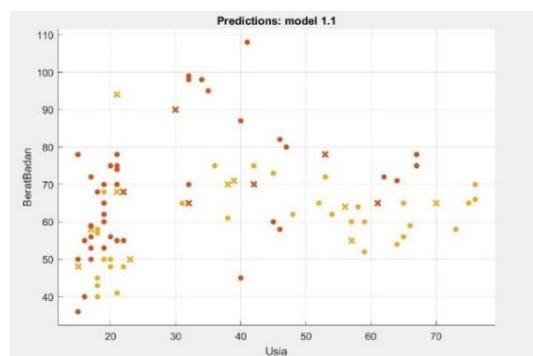
Model Fine KNN dengan $K = 1$ menghasilkan tingkat akurasi tertinggi sebesar 93,9%. Matriks kebingungan menunjukkan bahwa kesalahan klasifikasi tersebar secara proporsional, dan akurasi antar kelas berkisar antara 92% hingga 96%, menandakan bahwa fitur yang dipilih serta tahapan pra-pemrosesan telah diterapkan secara optimal.



Gambar 5. Hasil Visualisasi Menggunakan Model Confusion Matrix

2. Model Scatter Plot

Visualisasi scatter plot mengilustrasikan bahwa fitur usia dan berat badan cukup efektif dalam membedakan antar kategori tekanan darah. Namun, masih terdapat area tumpang tindih antara kelas prahipertensi dan hipertensi awal, yang mengindikasikan perlunya eksplorasi fitur tambahan seperti variabilitas detak jantung untuk meningkatkan kinerja model.

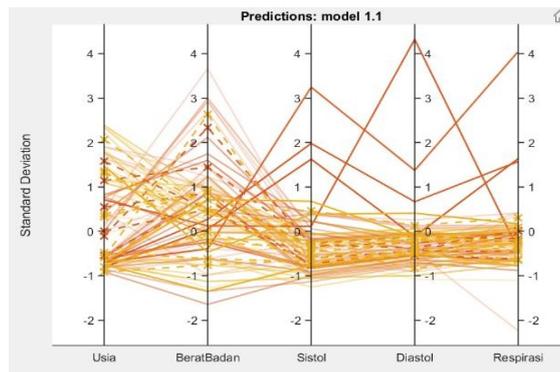


Gambar 6. Hasil Visualisasi Menggunakan Model Scatter Plot

3. Model Parallel Coordinates Plot

Visualisasi ini memperlihatkan hubungan antar fitur penting seperti usia, berat badan, tekanan darah sistolik dan diastolik, serta respirasi. Dapat diamati bahwa individu dalam kategori hipertensi cenderung memiliki nilai sistol dan diastol yang tinggi serta usia yang lebih lanjut. Beberapa

lintasan silang antar kelas mencerminkan keberadaan individu dengan karakteristik campuran, sehingga menyulitkan proses klasifikasi.



Gambar 7. Hasil Visualisasi menggunakan model Parallel Coordinates Plot

C. Pembahasan

1. Tingkat Akurasi Analisis Google Colab

Setelah proses pengolahan dan implementasi algoritma K-Nearest Neighbor dilakukan di Google Colab, hasil klasifikasi tekanan darah menunjukkan bahwa model mampu mengenali pola fisiologis dengan baik. Data sinyal PPG beserta variabel pendukung seperti usia, berat badan, tekanan sistolik, diastolik, dan respirasi telah diproses secara optimal menggunakan library machine learning yang lengkap, diikuti dengan reduksi dimensi melalui PCA untuk menghasilkan visualisasi scatter plot yang memaparkan distribusi kelas secara jelas.

```

Akurasi:
0.9285714285714286

Classification Report:

```

	precision	recall	f1-score	support
Hipertensi Krisis	1.00	1.00	1.00	1
Hipertensi Stage 1	0.75	0.75	0.75	4
Hipertensi Stage 2	0.89	1.00	0.94	8
Hipotensi	1.00	1.00	1.00	8
Normal	1.00	1.00	1.00	3
Prahipertensi	1.00	0.75	0.86	4

Gambar 8. Tingkat Akurasi Menggunakan Platform Analisis Google Colab

2. Tingkat Akurasi Analisis MATLAB

Analisis lanjutan dengan MATLAB dengan keunggulan dalam pemrosesan sinyal dan analisis statistik memungkinkan penyajian visual interaktif melalui scatter plot, diagram koordinat paralel, dan evaluasi kinerja model menggunakan confusion matrix. Evaluasi menunjukkan bahwa mencapai akurasi sebesar 93,9% dengan distribusi kesalahan yang minimal, menandakan efisiensi dan keandalan metode dalam mengklasifikasikan status hipertensi. Integrasi kedua platform ini tidak hanya meningkatkan efisiensi pengolahan data, tetapi juga menyediakan dasar yang kuat untuk pengambilan keputusan medis secara real-time.

1.1 ☆ KNN	Accuracy: 93.9%
Last change: Fine KNN	5/5 features
1.2 ☆ KNN	Accuracy: 83.8%
Last change: Medium KNN	5/5 features
1.3 ☆ KNN	Accuracy: 66.8%
Last change: Coarse KNN	5/5 features

Gambar 9. Tingkat Akurasi Menggunakan Platform Analisis MATLAB

3. Perbandingan dengan Metode Lain

Meski penelitian ini memfokuskan pada algoritma KNN, referensi literatur memperlihatkan bahwa pendekatan seperti SVM dan Random Forest (RF) juga banyak digunakan untuk permasalahan klasifikasi tekanan darah. Salah satu studi oleh Gentilin (2025) membandingkan tujuh model dan menyimpulkan bahwa KNN menunjukkan performa akurasi yang sebanding dengan SVM dan RF, serta memiliki keunggulan dari segi efisiensi komputasi. Hal ini memperkuat alasan pemilihan KNN dalam pengembangan sistem yang ditujukan untuk perangkat wearable.

D. Evaluasi Hasil

Implementasi pada dua platform berbeda, yaitu Google Colab dan MATLAB, menghasilkan tingkat akurasi yang konsisten. Visualisasi melalui metode PCA dan parallel coordinates memberikan gambaran yang jelas mengenai kontribusi masing-masing fitur terhadap keputusan klasifikasi. Evaluasi menggunakan confusion matrix mengonfirmasi keakuratan tinggi yang dicapai oleh model, dengan nilai hingga 93,9%. Meski demikian, ditemukannya outlier serta tumpang tindih antar beberapa kelas menunjukkan bahwa model masih memiliki ruang untuk perbaikan, seperti melalui pendekatan ensemble learning atau algoritma berbasis deep learning.

Platform Analisis	Tingkat Akurasi
Google Colab	92.8%
MATLAB	93.9%

Tabel I. Evaluasi Hasil

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi hipertensi berbasis algoritma KNN dengan akurasi tinggi (antara 92,8% hingga 93,9%) menggunakan sinyal PPG. Pendekatan ini mengatasi keterbatasan metode pengukuran tekanan darah konvensional (misalnya, efek white coat) dan menawarkan solusi non-invasif yang siap untuk diintegrasikan ke dalam perangkat wearable untuk monitoring kesehatan secara real-time. Namun, terdapat beberapa keterbatasan seperti sensitivitas terhadap noise sinyal dan optimalisasi nilai KK yang perlu dieksplorasi lebih lanjut. Disarankan agar penelitian lanjutan membandingkan performa KNN secara langsung dengan model lain seperti SVM dan Random Forest, serta mengeksplorasi integrasi sistem ini ke dalam aplikasi mobile untuk mendukung pemantauan klinis yang lebih luas.

REFERENSI

- [1] L. Zhao et al., “Emerging sensing and modeling technologies for wearable and cuffless blood pressure monitoring,” *NPJ Digit Med*, vol. 6, no. 1, p. 93, May 2023, doi: 10.1038/s41746-023-00835-6.
- [2] S. M. S. Islam et al., “Wearable cuffless blood pressure monitoring devices: a systematic review and meta-analysis,” *European Heart Journal - Digital Health*, vol. 3, no. 2, pp. 323–337, Jul. 2022, doi: 10.1093/ehjdh/ztac021.
- [3] T. Le et al., “Continuous Non-Invasive Blood Pressure Monitoring: A Methodological Review on Measurement Techniques,” *IEEE Access*, vol. 8, pp. 212478–212498, 2020, doi: 10.1109/ACCESS.2020.3040257.
- [4] G. Sannino, I. De Falco, and G. De Pietro, “Non-Invasive Risk Stratification of Hypertension: A Systematic Comparison of Machine Learning Algorithms,” *Journal of Sensor and Actuator Networks*, vol. 9, no. 3, p. 34, Jul. 2020, doi: 10.3390/jsan9030034.
- [5] J. Cano, L. Fácila, J. M. Gracia-Baena, R. Zangróniz, R. Alcaraz, and J. J. Rieta, “The Relevance of Calibration in Machine Learning-Based Hypertension Risk Assessment Combining Photoplethysmography and Electrocardiography,” *Biosensors (Basel)*, vol. 12, no. 5, p. 289, May 2022, doi: 10.3390/bios12050289.
- [6] S. Andriekutė, K. Bagdonaitė, M. Savickas, and K. Ziuteliienė, “Photoplethysmography technology use in smart devices for early diagnosis of arterial hypertension: a systematic review,” *Arterial Hypertension*, vol. 28, no. 0, pp. 12–17, Oct. 2024, doi: 10.5603/ah.94874.
- [7] J. Hong, M. Nandi, Y. Zheng, and J. Alastruey, “Hypertension Screening via Awake-Sleep Differences in Photoplethysmogram Signals,” May 29, 2025. doi: 10.1101/2025.05.22.25328194.
- [8] K. Welykholowa et al., “Multimodal Photoplethysmography-Based Approaches for Improved Detection of Hypertension,” *J Clin Med*, vol. 9, no. 4, p. 1203, Apr. 2020, doi: 10.3390/jcm9041203.
- [9] Y. Liang, Z. Chen, R. Ward, and M. Elgendi, “Photoplethysmography and Deep Learning: Enhancing Hypertension Risk Stratification,” *Biosensors (Basel)*, vol. 8, no. 4, p. 101, Oct. 2020, doi: 10.3390/bios8040101.
- [10] S. Min et al., “Wearable blood pressure sensors for cardiovascular monitoring and machine learning algorithms for blood pressure estimation,” *Nat Rev Cardiol*, Feb. 2025, doi: 10.1038/s41569-025-01127-0.
- [11] H. Tjahjadi and K. Ramli, “Noninvasive blood pressure classification based on photoplethysmography using K-nearest neighbors algorithm: A feasibility study,” *Information (Switzerland)*, vol. 11, no. 2, Feb. 2020, doi: 10.3390/info11020093.
- [12] A. Gentilin, “Comparison of seven machine learning models in hypertension classification using photoplethysmographic and anthropometric data,” *J Med Eng Technol*, pp. 1–7, May 2025, doi: 10.1080/03091902.2025.2506419.
- [13] S. Iqbal, J. Bacardit, B. Griffiths, and J. Allen, “Deep learning classification of systemic sclerosis from multi-site photoplethysmography signals,” *Front Physiol*, vol. 14, 2023, doi: 10.3389/fphys.2023.1242807.
- [14] A. Appel and R. P. Theart, “Investigating the Design of a Photoplethysmography Device for Vital Sign Monitoring,” *Sensors*, vol. 25, no. 6, p. 1875, Mar. 2025, doi: 10.3390/s25061875.
- [15] S. N. A. Ismail, N. A. Nayan, R. Jaafar, and Z. May, “Recent Advances in Non-Invasive Blood Pressure Monitoring and Prediction Using a Machine Learning Approach,” Aug. 01, 2022, MDPI. doi: 10.3390/s22166195.
- [16] Y. N. Fuadah and K. M. Lim, “Classification of Blood Pressure Levels Based on Photoplethysmogram and Electrocardiogram Signals with a Concatenated Convolutional Neural Network,” *Diagnostics*, vol. 12, no. 11, Nov. 2022, doi: 10.3390/diagnostics12112886.
- [17] J. Alam, M. F. Khan, M. A. Khan, R. Singh, M. Mundazeer, and P. Kumar, “A Systematic Approach Focused on Machine Learning Models for Exploring the Landscape of Physiological Measurement and Estimation Using Photoplethysmography (PPG),” *J Cardiovasc Transl Res*, vol. 17, no. 3, pp. 669–684, Jun. 2024, doi: 10.1007/s12265-023-10462-x.
- [18] H. Lin et al., “Longitudinal Wrist PPG Analysis for Reliable Hypertension Risk Screening Using Deep Learning,” Nov. 2024, [Online]. Available: <http://arxiv.org/abs/2411.11863>