

BAB I PENDAHULUAN

1.1 Latar Belakang

Tekanan darah merupakan salah satu indikator fisiologis utama yang digunakan secara luas dalam praktik klinis untuk menilai kondisi sistem kardiovaskular serta risiko terjadinya berbagai penyakit, seperti hipertensi, penyakit jantung koroner, dan stroke. Kondisi tekanan darah yang tidak terkontrol diketahui berkontribusi secara signifikan terhadap peningkatan morbiditas dan mortalitas akibat penyakit kardiovaskular. Secara global, hipertensi masih menjadi masalah kesehatan utama karena prevalensinya yang tinggi serta tingkat pengendalian yang relatif rendah pada berbagai populasi (NCD Risk Factor Collaboration, 2021).

Salah satu tantangan utama dalam pengendalian hipertensi adalah sifatnya yang sering tidak menimbulkan gejala pada tahap awal. Banyak individu tidak menyadari bahwa tekanan darahnya berada pada kondisi meningkat atau hipertensi hingga muncul komplikasi yang lebih serius. Oleh karena itu, hipertensi sering disebut sebagai *silent killer*. Kondisi ini menunjukkan pentingnya upaya skrining dan pemantauan tekanan darah secara rutin sebagai langkah pencegahan dan deteksi dini (American Heart Association, 2023; McEvoy et al., 2024).

Metode pengukuran tekanan darah yang umum digunakan saat ini masih didominasi oleh perangkat berbasis manset (*cuff-based sphygmomanometer*). Meskipun metode ini memiliki akurasi klinis yang baik, penggunaannya relatif kurang nyaman dan tidak praktis untuk pemantauan jangka panjang atau berkelanjutan. Keterbatasan tersebut mendorong berkembangnya penelitian mengenai metode pemantauan tekanan darah non-invasif tanpa manset (*cuffless blood pressure monitoring*) yang memungkinkan pengukuran lebih fleksibel dan berkelanjutan (Ismail & Manaf, 2022; Charlton et al., 2022).

Seiring dengan perkembangan teknologi sensor optik, teknik *photoplethysmography* (PPG) menjadi salah satu pendekatan yang banyak digunakan untuk pemantauan parameter kardiovaskular secara non-invasif. Sinyal PPG merepresentasikan perubahan volume darah pada jaringan perifer dan telah banyak diimplementasikan pada perangkat *wearable* untuk pemantauan denyut jantung dan parameter fisiologis lainnya (Elgendi et al., 2020; Kim & Baek, 2023). Penggunaan PPG berbasis LED hijau banyak dipilih karena memiliki sensitivitas yang baik terhadap perubahan volume darah kapiler serta ketahanan yang lebih baik terhadap artefak gerakan dibandingkan panjang gelombang lainnya, sehingga sesuai untuk sistem berdaya rendah (Lee et al., 2020; Rehman et al., 2024). Meskipun demikian, sinyal PPG tidak secara langsung merepresentasikan tekanan darah, melainkan mencerminkan dinamika aliran darah perifer. Hubungan antara sinyal PPG dan tekanan darah bersifat tidak langsung serta dipengaruhi oleh berbagai faktor fisiologis, seperti elastisitas pembuluh darah dan kondisi hemodinamik individu. Selain itu, sinyal PPG sangat sensitif terhadap artefak gerakan dan variasi antar individu, sehingga kualitas sinyal menjadi faktor penting yang menentukan keandalan analisis dan interpretasi hasil (Charlton et al., 2022; Desquins et al., 2022; Rinkevičius, 2023).

Salah satu pendekatan yang dapat digunakan untuk mengekstraksi informasi fisiologis dari sinyal PPG adalah analisis *Pulse Rate Variability* (PRV), yaitu variabilitas denyut yang dihitung dari interval antar puncak sinyal PPG. Berbeda dengan *Heart Rate Variability* (HRV), PRV merefleksikan dinamika denyut perifer dan

telah dilaporkan memiliki potensi sebagai biomarker fisiologis tersendiri (Yuda et al., 2020; Mejía-Mejía & Kyriacou, 2022). Sejumlah penelitian menunjukkan bahwa fitur-fitur PRV serta karakteristik statistik sinyal PPG dapat dimanfaatkan untuk analisis dan klasifikasi kondisi fisiologis menggunakan pendekatan pembelajaran mesin pada berbagai domain kesehatan, termasuk pemantauan kondisi kardiovaskular dan status fisiologis lainnya (Song & Lee, 2025; Brophy et al., 2021; Almutairi et al., 2022; Liu et al., 2025). Namun, pemanfaatan PRV dan fitur sinyal PPG dalam sistem klasifikasi kondisi tekanan darah masih sangat bergantung pada kualitas sinyal dan strategi ekstraksi fitur yang digunakan.

Dalam beberapa tahun terakhir, pengolahan sinyal PPG untuk analisis tekanan darah banyak dikembangkan dengan memanfaatkan pendekatan *Machine Learning* (ML) dan *Deep Learning* (DL). Sejumlah penelitian terdahulu mengembangkan pendekatan dengan karakteristik dan tujuan yang berbeda-beda, mulai dari estimasi tekanan darah berbasis DL hingga klasifikasi kondisi tekanan darah berbasis fitur. Attya (2024) mengusulkan metode estimasi tekanan darah berbasis sinyal PPG dengan merepresentasikan sinyal dalam bentuk citra waktu–frekuensi dan menerapkan model *Convolutional Neural Network* (CNN). Pendekatan ini menunjukkan performa yang tinggi, namun memerlukan arsitektur model yang kompleks serta sumber daya komputasi yang besar. Selanjutnya, Hong et al. (2024) mengembangkan pendekatan estimasi tekanan darah berbasis PPG menggunakan model *Long Short-Term Memory* (LSTM) untuk mempelajari hubungan temporal sinyal secara *end-to-end*. Meskipun mampu menangkap dinamika temporal sinyal dengan baik, pendekatan ini masih bergantung pada data berskala besar dan proses pelatihan yang intensif secara komputasi. Sebagai pembandingan terhadap pendekatan DL tersebut, Song dan Lee (2025) mengusulkan pendekatan klasifikasi kondisi tekanan darah berbasis fitur morfologi dan fitur fisiologis sinyal PPG menggunakan algoritma ML berbasis fitur. Pendekatan ini menawarkan kompleksitas komputasi yang lebih rendah serta tingkat interpretabilitas yang lebih baik dibandingkan pendekatan DL, sehingga lebih relevan untuk sistem skrining awal dan pemantauan berdaya rendah. Namun, pendekatan tersebut belum secara eksplisit mengintegrasikan evaluasi kualitas sinyal PPG dan masih menggunakan konfigurasi sensor serta data yang relatif kompleks. Berdasarkan ketiga penelitian terdahulu tersebut, dapat disimpulkan bahwa meskipun pendekatan berbasis DL dan ML menunjukkan potensi yang besar dalam pemantauan tekanan darah non-invasif, masih terdapat keterbatasan dari sisi kompleksitas komputasi, kebutuhan data, serta integrasi kualitas sinyal. Hal ini membuka peluang pengembangan pendekatan klasifikasi kondisi tekanan darah yang lebih sederhana, efisien secara komputasi, dan mudah diimplementasikan pada sistem IoT berdaya rendah.

Integrasi teknologi IoT memungkinkan data fisiologis dari sensor dikirimkan dan divisualisasikan secara *near real-time* untuk mendukung pemantauan jarak jauh dan berkelanjutan. Namun, dalam penerapannya, keterbatasan sumber daya perangkat seperti kapasitas komputasi, memori, dan konsumsi daya menjadi pertimbangan penting, sehingga pada banyak studi pemrosesan sinyal dan inferensi model ML masih dilakukan secara terpusat pada komputer atau server sebagai tahap awal pengembangan sistem. Oleh karena itu, pemilihan pendekatan analisis dan klasifikasi yang relatif ringan dan efisien secara komputasi menjadi relevan untuk mendukung potensi implementasi pada sistem IoT berdaya rendah pada tahap pengembangan selanjutnya, tanpa mengorbankan keandalan analisis (Abdulmalek et al., 2022; Kouchaki et al., 2024; Uddin & Koo, 2024).

Berdasarkan uraian tersebut, penelitian ini difokuskan pada pengembangan sistem pemantauan tekanan darah berbasis sinyal PPG yang sederhana, hemat daya, dan mudah diimplementasikan. Secara khusus, masih terbatas penelitian yang secara eksplisit mengintegrasikan evaluasi kualitas sinyal PPG dengan pendekatan klasifikasi kondisi tekanan darah normal dan tidak normal berbasis satu sensor PPG LED hijau dalam kerangka sistem IoT. Oleh karena itu, penelitian ini mengembangkan pendekatan klasifikasi kondisi tekanan darah berbasis fitur PRV dan fitur statistik sinyal PPG dengan memanfaatkan algoritma ML berbasis pohon keputusan dan teknik *boosting* yang relatif ringan dan efisien secara komputasi, yaitu *Random Forest*, *XGBoost*, dan *Light-GBM*.

Penelitian ini dikembangkan sebagai studi awal (*proof-of-concept*) untuk sistem skrining tekanan darah non-invasif berbasis sinyal PPG dan IoT. Dengan demikian, penelitian ini tidak bertujuan untuk mengestimasi nilai tekanan darah secara numerik, melainkan mengklasifikasikan kondisi tekanan darah ke dalam dua kelas, yaitu normal dan tidak normal. Kelas tidak normal mencakup kategori tekanan darah meningkat dan hipertensi berdasarkan pedoman *American Heart Association* (AHA) dan *American College of Cardiology* (ACA), sehingga hasil klasifikasi yang diperoleh dimaksudkan sebagai indikasi awal kondisi tekanan darah dan bukan sebagai alat diagnosis klinis atau pengganti pengukuran tekanan darah standar.

1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini diantaranya adalah:

1. Merancang dan membangun sistem pemantauan kondisi tekanan darah berbasis sinyal PPG LED hijau yang terintegrasi dengan mikrokontroler ESP32.
2. Mengevaluasi kualitas sinyal PPG sebagai dasar ekstraksi fitur PRV dan fitur statistik sinyal.
3. Mengembangkan dan mengevaluasi model ML untuk mengklasifikasikan kondisi tekanan darah normal dan tidak normal serta menampilkan hasil klasifikasi melalui aplikasi berbasis IoT.

1.3 Manfaat Penelitian

Adapun manfaat dari penelitian ini diantaranya adalah:

1. Menyediakan demonstrasi sistem pemantauan tekanan darah non-invasif berbasis PPG dan IoT sebagai *proof-of-concept*.
2. Mendukung pengembangan sistem pemantauan fisiologis berbasis IoT dan ML ringan dengan pendekatan klasifikasi sederhana.
3. Menjadi referensi ilmiah dalam pemanfaatan sinyal PPG dan PRV untuk klasifikasi kondisi tekanan darah pada perangkat berdaya rendah.

BAB II METODE PENELITIAN

2.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada bulan Maret 2025 Januari 2026 bertempat di Laboratorium Elektronika dan Instrumentasi Departemen Fisika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin dan Puskesmas Tamalanrea Jaya, Kota Makassar, Provinsi Sulawesi Selatan

2.2 Peralatan Penelitian

Alat yang digunakan dan bahan pada penelitian ini yaitu :

1. *Board ESP32* (30 Pin) berfungsi sebagai mikrokontroler pengiriman data sensor melalui koneksi Wi-Fi.
2. *Pulse Sensor Amped*, sensor optik untuk mendeteksi sinyal PPG yang merepresentasikan perubahan volume darah di ujung jari.
3. Kabel *Jumper* berfungsi sebagai penghubung antar komponen elektronik.
4. Laptop, digunakan untuk pemrograman, pemrosesan sinyal, dan analisis data dengan *Jupyter Notebook*.
5. *Power bank*, digunakan sebagai sumber daya bagi mikrokontroler.
6. *Box alat*, wadah pelindung perangkat keras.
7. *Case sensor*, pelindung *Pulse Sensor Amped* untuk memastikan stabilitas pengukuran.
8. Tensimeter digital Omron HEM 7156A digunakan sebagai alat referensi untuk pelabelan kondisi tekanan darah normal dan tidak normal.

2.3 Definisi Kelas Tekanan Darah

Pada penelitian ini, kondisi tekanan darah diklasifikasikan ke dalam dua kelas, yaitu normal dan tidak normal, yang digunakan sebagai label kelas pada proses klasifikasi ML. Penentuan kelas dilakukan berdasarkan nilai tekanan darah sistolik dan tekanan darah diastolik yang diukur menggunakan tensimeter digital Omron sebagai alat referensi. Klasifikasi tekanan darah pada penelitian ini mengacu pada pedoman AHA dan ACC, yang hingga saat ini masih digunakan secara luas sebagai rujukan dalam penelitian dan praktik klinis tekanan darah (American Heart Association, 2023; McEvoy et al., 2024).

Kriteria klasifikasi tekanan darah yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1.

Tabel 1. Definisi kelas tekanan darah

Kelas	Kriteria
Normal	Tekanan darah sistolik < 120 mmHg dan tekanan darah diastolik < 80 mmHg
Tidak Normal	Tekanan darah sistolik $\geq$ 120 mmHg atau tekanan darah diastolik $\geq$ 80 mmHg

Berdasarkan pedoman tersebut, tekanan darah dengan nilai sistolik 120–129 mmHg dan diastolik < 80 mmHg dikategorikan sebagai tekanan darah meningkat, sedangkan hipertensi ditetapkan pada nilai sistolik ≥ 130 mmHg atau diastolik ≥ 80 mmHg. Klasifikasi ini dipertahankan dalam pembaruan rekomendasi AHA terbaru sebagai dasar skrining dan pengelompokan risiko tekanan darah pada populasi dewasa (American Heart Association, 2023).

Dalam penelitian ini, kategori tekanan darah meningkat dan hipertensi digabungkan ke dalam satu kelas tidak normal. Pendekatan ini digunakan untuk menyederhanakan skema klasifikasi dan menyesuaikan dengan tujuan penelitian sebagai sistem skrining awal tekanan darah non-invasif, sehingga fokus analisis diarahkan pada perbedaan antara kondisi tekanan darah dalam rentang normal dan kondisi di luar rentang normal. Pengelompokan ini tidak dimaksudkan untuk menggantikan diagnosis klinis, melainkan sebagai pendekatan awal dalam pemantauan tekanan darah.


2.4 Metode Penelitian

Penelitian ini diawali dengan studi literatur terkait pengembangan sistem pemantauan fisiologis berbasis IoT dan ML. Sistem yang dikembangkan terdiri atas perangkat keras dan perangkat lunak, di mana sensor PPG berbasis LED hijau (*Pulse Sensor Amped*) diintegrasikan dengan mikrokontroler ESP32 sebagai node akuisisi data. LED hijau dengan panjang gelombang sekitar 520–560 nm dipilih karena memiliki sensitivitas yang baik terhadap perubahan volume darah kapiler serta ketahanan terhadap artefak gerakan, sehingga sesuai untuk sistem *wearable* berdaya rendah (Lee et al., 2020; Kim & Baek, 2023; Tamura et al., 2014).

Sinyal PPG dibaca oleh ESP32 dengan frekuensi *sampling* tetap sebesar 100 Hz dan dikirimkan ke komputer terpusat melalui jaringan IoT. Seluruh proses *filtering*, ekstraksi fitur, dan klasifikasi ML dilakukan pada komputer, sementara hasil klasifikasi dikirimkan kembali ke aplikasi Blynk sebagai antarmuka visualisasi.

Akuisisi sinyal PPG dilakukan selama 80 detik pada setiap subjek, kemudian disegmentasi menjadi *window* berdurasi 10 detik. Setiap *window* diproses menggunakan *bandpass filtering* dan *smoothing* untuk mengurangi derau dan memperjelas morfologi sinyal. Kualitas sinyal dievaluasi pada tingkat *window* untuk menyeleksi segmen yang layak dianalisis, mengingat kualitas sinyal PPG sangat memengaruhi keandalan analisis berbasis fitur dan pembelajaran mesin (Elgendi et al., 2020; Desquins et al., 2022; Rinkevičius, 2023).

Pengukuran tekanan darah dilakukan secara sinkron menggunakan tensimeter digital Omron sebagai alat referensi. *Window* sinyal yang lolos seleksi kualitas digunakan untuk ekstraksi fitur PRV dan fitur statistik sinyal PPG. Fitur-fitur tersebut kemudian diagregasi pada tingkat subjek menggunakan nilai rata-rata, simpangan baku, nilai minimum, dan maksimum untuk membentuk satu vektor fitur, yang selanjutnya digunakan sebagai masukan ke dalam model ML untuk mengklasifikasikan kondisi tekanan darah menjadi normal dan tidak normal.



Gambar 1. Tahapan penelitian

2.4.1 Subjek Penelitian dan Etika

Penelitian ini melibatkan subjek sukarelawan yang memenuhi kriteria inklusi penelitian. Sebelum pengambilan data, seluruh subjek diberikan penjelasan mengenai tujuan dan prosedur penelitian. Partisipasi bersifat sukarela dan persetujuan diberikan secara lisan (*verbal informed consent*). Data yang dikumpulkan bersifat anonim dan digunakan semata-mata untuk keperluan penelitian, sehingga kerahasiaan dan privasi subjek tetap terjaga.


2.4.2 Karakteristik Subjek dan Data Penelitian

Subbab ini menyajikan karakteristik subjek dan data penelitian yang digunakan pada tahap analisis dan evaluasi sistem. Data yang digunakan merupakan data primer hasil pengambilan sinyal PPG secara langsung dari 90 subjek penelitian yang memenuhi kriteria inklusi, tanpa memanfaatkan dataset eksternal maupun repositori data publik. Seluruh data yang diperoleh kemudian dibagi menjadi 70 subjek sebagai data latih (*training*) dan 20 subjek sebagai data uji (*testing*) untuk keperluan klasifikasi ML. Distribusi kondisi tekanan darah pada keseluruhan subjek disajikan pada Tabel 2.

Tabel 2. Tabel karakteristik subjek	
Parameter	Nilai
Jumlah subjek	90
Rentang usia	20-70 tahun
Normal	45
Tidak Normal	45


2.5 Perancangan Perangkat Keras

Perancangan perangkat keras pada sistem ini dibagi menjadi tiga bagian utama, yaitu *Input*, *Process*, dan *User Interface*, sebagaimana ditunjukkan pada Gambar 2. Bagian *Input* berfungsi untuk memperoleh data fisiologis dari pasien. Pada tahap ini, sinyal denyut nadi diperoleh menggunakan *Pulse Sensor Amped* yang ditempatkan pada tubuh pasien untuk menangkap sinyal PPG. Bagian *process* merupakan tahap pengolahan data yang melibatkan mikrokontroler ESP32 sebagai pusat akuisisi dan pengiriman data. ESP32 membaca sinyal dari sensor kemudian mengirimkannya ke laptop untuk pemrosesan lebih lanjut. Laptop digunakan untuk analisis data dan penerapan metode ML dalam mengklasifikasikan kondisi kesehatan. Sistem ini didukung oleh *power bank* sebagai sumber daya portabel agar perangkat dapat digunakan secara fleksibel. Bagian *User Interface* berfungsi menampilkan hasil pemrosesan data kepada pengguna. Hasil analisis dikirimkan ke aplikasi Blynk sehingga informasi kondisi kesehatan dapat dipantau secara *near real-time* melalui perangkat pengguna.



Gambar 2. Diagram blok sistem

Pada penelitian ini, *Pulse Sensor Amped* digunakan untuk mendeteksi sinyal PPG yang merepresentasikan perubahan volume darah pada jaringan perifer, khususnya di ujung jari. Sinyal PPG yang diperoleh selanjutnya dikirimkan ke ESP32 untuk diproses dan diteruskan ke sistem analisis. Rangkaian perangkat keras yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3.



Gambar 3. Rangkaian perangkat keras

2.6 Perancangan Perangkat Lunak

Perancangan perangkat lunak pada penelitian ini difokuskan pada pengembangan sistem ML untuk klasifikasi kondisi tekanan darah serta antarmuka pemantauan berbasis IoT. Secara umum, perangkat lunak terdiri atas dua komponen utama, yaitu

modul pelatihan dan evaluasi model ML serta modul antarmuka pengguna untuk menampilkan hasil klasifikasi.

Seluruh proses pengolahan data, ekstraksi fitur, pelatihan, dan evaluasi model ML diimplementasikan menggunakan bahasa pemrograman Python pada lingkungan Jupyter Notebook. Sementara itu, hasil prediksi model digunakan pada sistem IoT dan ditampilkan melalui aplikasi Blynk sebagai media pemantauan kondisi tekanan darah secara *near real-time*.

2.6.1 Perancangan Model ML

Sinyal PPG dari setiap subjek terlebih dahulu diproses melalui tahapan prapemrosesan yang meliputi *bandpass filtering*, *smoothing*, serta segmentasi sinyal menjadi *window* berdurasi 10 detik. Tahapan ini bertujuan untuk mengurangi derau dan memperjelas morfologi gelombang PPG sehingga puncak denyut dapat terdeteksi secara lebih stabil, sebagaimana umum diterapkan dalam analisis sinyal PPG pada perangkat *wearable* (Elgendi et al., 2020; Desquins et al., 2022).

Kualitas setiap *window* kemudian dievaluasi sebelum tahap ekstraksi fitur untuk memastikan keandalan sinyal yang dianalisis. Evaluasi kualitas dilakukan dengan mempertimbangkan kestabilan dan karakteristik morfologi sinyal PPG, mengingat kualitas sinyal sangat memengaruhi keakuratan analisis berbasis fitur dan ML (Desquins et al., 2022; Rinkevičius, 2023). *Window* dengan kualitas sinyal yang tidak memenuhi kriteria dikeluarkan dari analisis untuk meminimalkan pengaruh derau dan artefak gerakan. Evaluasi kualitas sinyal dilakukan pada tingkat *window* untuk memastikan bahwa hanya segmen sinyal dengan morfologi yang stabil dan minim artefak yang digunakan pada tahap ekstraksi fitur dan pelatihan model. Pendekatan ini bertujuan untuk menjaga konsistensi representasi fitur tingkat subjek dan meningkatkan keandalan proses klasifikasi berbasis ML.

Dari setiap *window* yang lolos seleksi kualitas, dilakukan ekstraksi fitur PRV dan fitur statistik sinyal PPG. PRV dihitung berdasarkan interval antar puncak sinyal PPG dan merefleksikan dinamika denyut perifer yang berkaitan dengan sistem kardiovaskular, sehingga dapat dimanfaatkan sebagai biomarker fisiologis berbasis PPG (Yuda et al., 2020; Mejía-Mejía & Kyriacou, 2022). Selain itu, fitur statistik seperti nilai rata-rata, simpangan baku, serta nilai minimum dan maksimum sinyal digunakan untuk merepresentasikan karakteristik morfologi dan kestabilan sinyal PPG.

Fitur-fitur yang diperoleh dari beberapa *window* dalam satu subjek selanjutnya diintegrasikan menggunakan nilai rata-rata, simpangan baku, nilai minimum, dan maksimum sehingga membentuk satu vektor fitur tingkat subjek. Dengan pendekatan ini, setiap subjek direpresentasikan oleh satu vektor fitur yang merangkum informasi dari seluruh *window* valid, sehingga mengurangi pengaruh variabilitas antar *window* dan mencegah bias akibat korelasi antar segmen sinyal dalam satu subjek (Brophy et al., 2021; Song & Lee, 2025).

Dataset fitur tingkat subjek selanjutnya digunakan pada tahap pelatihan dan evaluasi model ML untuk mengklasifikasikan kondisi tekanan darah ke dalam dua kelas, yaitu normal dan tidak normal. Proses evaluasi dilakukan menggunakan skema *Stratified K-Fold Cross-Validation* dengan jumlah 5 *fold*. Pada setiap *fold*,

dataset yang terdiri dari 70 subjek dibagi menjadi sekitar 80% data latih (± 56 subjek) dan 20% data uji (± 14 subjek), dengan tetap mempertahankan proporsi kelas normal dan tidak normal.

Untuk mengatasi ketidakseimbangan kelas pada data latih, diterapkan metode *Synthetic Minority Over-sampling Technique* (SMOTE). Oversampling hanya dilakukan pada data latih di setiap *fold*, sedangkan data uji tidak dikenai oversampling guna mencegah terjadinya bias pada proses evaluasi model (Ismail & Manaf, 2022). Model klasifikasi dibangun menggunakan tiga algoritma, yaitu *Random Forest*, *XGBoost*, dan *LightGBM*. *Random Forest* dipilih karena kemampuannya dalam menangani hubungan nonlinier dan ketahanannya terhadap *overfitting*, sedangkan *XGBoost* dan *LightGBM* merupakan algoritma *gradient boosting* yang efektif dalam mempelajari pola kompleks dari data berdimensi tinggi. Untuk meningkatkan stabilitas dan kemampuan generalisasi model, ketiga algoritma tersebut dikombinasikan menggunakan metode *Voting Ensemble* dengan pendekatan *soft voting*, di mana probabilitas keluaran dari masing-masing model digabungkan untuk menghasilkan prediksi akhir (Song & Lee, 2025; Kouchaki et al., 2024).

Kinerja model dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* yang dihitung berdasarkan *confusion matrix*. Akurasi menunjukkan proporsi prediksi yang benar terhadap seluruh data, presisi merepresentasikan ketepatan prediksi pada kelas tidak normal, *recall* menunjukkan kemampuan model dalam mendeteksi kondisi tidak normal, sedangkan *F1-score* merupakan ukuran keseimbangan antara presisi dan *recall*. Penggunaan kombinasi metrik ini penting dalam aplikasi medis karena kesalahan dalam mendeteksi kondisi tidak normal memiliki implikasi yang lebih serius dibandingkan kesalahan pada kelas normal (Ismail & Manaf, 2022). Secara matematis, metrik evaluasi tersebut dirumuskan sebagai berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$


$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$F1-score = 2 \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

di mana TP (*True Positive*) menyatakan jumlah data tidak normal yang diprediksi tidak normal, TN (*True Negative*) menyatakan data normal yang diprediksi normal, FP (*False Positive*) menyatakan data normal yang salah diklasifikasikan sebagai tidak normal, dan FN (*False Negative*) menyatakan data tidak normal yang salah diklasifikasikan sebagai normal. Dalam konteks aplikasi klinis, nilai *recall* pada kelas tidak normal dipandang sebagai sensitivitas sistem, yaitu kemampuan dalam mendeteksi subjek dengan kondisi tekanan darah tidak normal, sedangkan *recall*

pada kelas normal merepresentasikan spesifisitas, yaitu kemampuan sistem dalam mengidentifikasi subjek dengan tekanan darah normal.

Alur keseluruhan proses pelatihan dan evaluasi model ML ditunjukkan pada Gambar 4.



Gambar 4. Pelatihan model ML

Pelatihan dan evaluasi model dilakukan menggunakan skema *Stratified K-Fold Cross-Validation*, di mana pada setiap lipatan data latih digunakan untuk melatih model dan data validasi digunakan untuk mengevaluasi kinerja model. Model hasil pelatihan selanjutnya digunakan pada tahap implementasi sistem, di mana sinyal PPG yang diperoleh dari sensor melalui ESP32 diproses untuk menghasilkan prediksi kondisi tekanan darah secara *near real-time* dan ditampilkan melalui sistem IoT.

2.6.2 Perancangan Modul Antarmuka

Perancangan modul antarmuka pada penelitian ini bertujuan menyediakan media pemantauan kondisi tekanan darah berbasis IoT yang dapat diakses secara *near real-time*. Aplikasi Blynk dipilih sebagai *platform* antarmuka karena mendukung komunikasi langsung dengan mikrokontroler ESP32 serta menyediakan komponen visualisasi data yang fleksibel dan mudah dikonfigurasi.

Perancangan dimulai dengan pembuatan akun pada Blynk *Cloud* dan pembuatan proyek baru dengan menentukan jenis perangkat ESP32 serta metode koneksi jaringan yang digunakan. Setelah proyek dibuat, sistem menghasilkan *authentication token* sebagai identitas unik perangkat. Token tersebut diintegrasikan ke dalam program mikrokontroler melalui Arduino IDE agar ESP32 dapat terhubung ke server Blynk dan melakukan pertukaran data secara daring.

Data sinyal PPG yang diperoleh dari sensor dikirim oleh ESP32 ke sistem pemrosesan berbasis Python pada Jupyter Notebook. Pada tahap ini dilakukan *pre-processing* sinyal, ekstraksi fitur, serta prediksi kondisi tekanan darah menggunakan model ML yang telah dilatih. Implementasi program pada ESP32 menunjukkan integrasi komunikasi Wi-Fi, pertukaran data menggunakan protokol UDP, serta konektivitas dengan Blynk *Cloud* yang memungkinkan perangkat mengirim data sinyal PPG dan menerima hasil prediksi untuk ditampilkan pada antarmuka IoT, sebagaimana ditunjukkan pada Gambar 5.

```

1  #define BLYNK_TEMPLATE_ID   "TMPL6bzm-Iom5"
2  #define BLYNK_TEMPLATE_NAME "ML Status Device"
3  #define BLYNK_AUTH_TOKEN    "eulx7bcnphScD2Em8ZF03NqRHTqGk3Z3"
4
5  #include <WiFi.h>
6  #include <WiFiUdp.h>
7  #include <BlynkSimpleEsp32.h>
8
9  // WIFI
10 const char* ssid   = "vivo Y21";
11 const char* password = "Isampa198";
12
13
14 // UDP CONFIG
15 WiFiUDP udp_tx; // ESP32 Python (PPG)
16 WiFiUDP udp_rx; // Python ESP32 (ML result)
17
18 const char* pythonIP = "10.207.61.129";
19 const int PORT_TX = 55555;
20 const int PORT_RX = 55556;
21
22
23 // SENSOR PPG
24 const int pulsePin = 34;

```

Gambar 5. Program ESP32 pada Arduino IDE untuk komunikasi Wi-Fi, UDP, dan Blynk.

Hasil pemrosesan tidak ditampilkan secara langsung pada sistem komputasi, melainkan dikirim kembali ke ESP32 sebagai keluaran sistem untuk diteruskan ke aplikasi Blynk. Proses pemrosesan dan klasifikasi sinyal PPG pada Jupyter Notebook mencakup tahapan *pre-processing*, ekstraksi fitur, serta klasifikasi menggunakan model *Voting Ensemble* yang telah dilatih sehingga menghasilkan prediksi kondisi tekanan darah beserta parameter pendukung, sebagaimana ditunjukkan pada Gambar 6.

```

prob = voting_model.predict_proba(df_egg)[0,1]
pred = int(prob >= OPTIMAL_THRESHOLD)

final_hr = np.mean(hr_list)
final_ssqi = np.mean(ssqi_list)

status = "NORMAL" if pred == 0 else "TIDAK_NORMAL"
quality = "BAIK" if final_ssqi >= 0.6 else "SEDANG" if final_ssqi >= 0.5 else "BURUK"

print("\n HASIL FINAL")
print("Status :", status)
print("HR      :", round(final_hr,1), "bpm")
print("SSQT     :", round(final_ssqi,1))
print("Prob     :", round(prob*100,1), "%")

# KIRIM KE ESP32
msg = f"{status},{round(prob*100,1)},{round(final_hr,1)},{quality}"
sock_tx.sendto(msg.encode(), (ESP32_IP, PORT_TX))
print(" Dikirim ke ESP32:", msg)
print(" SELESAI")

Voting Ensemble dimuat
Menunggu PPG dari ESP32...
Data PPG lengkap
PPG RAM tersimpan

HASIL FINAL
Status : TIDAK_NORMAL
HR      : 81.5 bpm
SSQT     : 0.452
Prob     : 53.9 %
Dikirim ke ESP32: TIDAK_NORMAL,53.9,81.5,BAIK
SELESAI

```

Gambar 6. Pemrosesan dan klasifikasi sinyal PPG serta pengiriman hasil prediksi ke ESP32.

Konfigurasi antarmuka IoT pada aplikasi Blynk dilakukan melalui pemetaan *datastream* berbasis virtual pin untuk menerima dan menampilkan data hasil pemrosesan dari ESP32 secara sistematis sebagaimana terlihat pada Gambar 7. Parameter yang divisualisasikan meliputi status kondisi tekanan darah, nilai *confidence* hasil prediksi, denyut jantung (*heart rate*), serta kualitas sinyal PPG.

Masing-masing parameter dipetakan ke virtual pin tertentu, yaitu Virtual Pin V0 untuk status kondisi tekanan darah, V1 untuk nilai *confidence*, V2 untuk denyut jantung, dan V3 untuk kualitas sinyal PPG berdasarkan nilai SSQI. Pemetaan ini memungkinkan komunikasi data berlangsung secara terstruktur, meningkatkan keterbacaan informasi, serta memudahkan pengelolaan dan pengembangan sistem.

Virtual Pin Datastream

General Expose to Automations

NAME: Status ALIAS: Status

PIN: V0 DATA TYPE: String

DEFAULT VALUE: NORMAL


☐ Enable history data

[ADVANCED SETTINGS](#)

Cancel Save

Gambar 7. Konfigurasi virtual pin *datastream* pada aplikasi Blynk.

Dashboard Blynk berfungsi sebagai media visualisasi yang menampilkan hasil prediksi kondisi tekanan darah beserta parameter pendukung secara *near real-time*. Antarmuka ini dapat diakses melalui perangkat bergerak seperti *smartphone* atau tablet sehingga sistem mendukung pemantauan jarak jauh yang praktis dan mudah dioperasikan. Diagram alur perancangan modul antarmuka dan aliran data sistem secara keseluruhan ditunjukkan pada Gambar 8.



Gambar 8. Diagram alur perancangan modul antarmuka.

2.7 Pengujian Kualitas Sinyal PPG

Pada penelitian ini tidak dilakukan kalibrasi sensor terhadap alat ukur tekanan darah eksternal karena sistem difokuskan pada klasifikasi kondisi tekanan darah, bukan pengukuran nilai tekanan darah secara *absolut*. Oleh karena itu, pengujian diarahkan pada evaluasi kualitas sinyal PPG yang dihasilkan oleh *Pulse Sensor Amped* berbasis LED hijau.

Evaluasi kualitas sinyal dilakukan untuk memastikan sinyal PPG layak dianalisis lebih lanjut, dengan mempertimbangkan morfologi sinyal, kestabilan amplitudo, konsistensi puncak denyut, serta nilai SSQI. Sinyal yang memenuhi kriteria kualitas digunakan pada tahap *pre-processing*, ekstraksi fitur, dan analisis berbasis machine learning. SSQI dihitung berdasarkan *skewness* sinyal PPG hasil *pre-processing* sebagai berikut:

$$SSQI = \left| \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^3 \right| \quad (5)$$

dengan x_i menyatakan nilai sinyal PPG pada sampel ke- i , N jumlah sampel dalam satu *window*, μ rata-rata sinyal, dan σ simpangan baku.

Penetapan ambang SSQI pada penelitian ini didasarkan pada karakteristik distribusi nilai SSQI pada data latih. Nilai SSQI sebesar 0,3 digunakan sebagai ambang minimum kelayakan segmen sinyal, sedangkan nilai 0,5 dan 0,8 digunakan sebagai batas kategorisasi kualitas sinyal buruk, sedang, dan baik. Ambang ini selanjutnya diterapkan secara konsisten pada data uji.

2.8 Pengujian Sistem

Pengujian sistem dilakukan terhadap keseluruhan sistem yang telah dirancang, yang mencakup pengujian perangkat keras dan perangkat lunak. Pengujian perangkat keras bertujuan untuk memastikan bahwa *Pulse Sensor Amped* dan mikrokontroler ESP32 dapat bekerja dengan baik dalam melakukan akuisisi sinyal PPG serta mengirimkan data ke sistem pemrosesan melalui koneksi serial dan jaringan.

Pengujian perangkat lunak dilakukan untuk memastikan bahwa proses *pre-processing*, ekstraksi fitur, serta klasifikasi kondisi tekanan darah menggunakan model ML berbasis *ensemble* dapat berjalan dengan baik. Model klasifikasi yang digunakan terdiri dari *Random Forest*, *XGBoost*, dan *LightGBM* yang dikombinasikan menggunakan metode *Voting Ensemble* dengan pendekatan *soft voting*. Selain itu, dilakukan pengujian integrasi sistem untuk memastikan bahwa hasil klasifikasi dapat dikirim dan ditampilkan dengan benar melalui aplikasi Blynk sebagai media pemantauan kondisi tekanan darah secara *near real-time*. Suatu hasil prediksi dinyatakan sesuai apabila label klasifikasi yang dihasilkan oleh model ML sama dengan klasifikasi tekanan darah berdasarkan pengukuran tensimeter digital Omron sebagai alat referensi.

2.9 Bagan Alir Sistem Kerja Alat

Bagan alir sistem kerja pada penelitian ini diawali dengan proses akuisisi sinyal denyut nadi menggunakan *Pulse Sensor Amped* berbasis LED hijau yang terhubung ke mikrokontroler ESP32. Sinyal PPG yang diperoleh dari sensor dibaca oleh ESP32


sebagai data mentah dan dikirimkan ke komputer melalui komunikasi data untuk diproses lebih lanjut pada lingkungan Python (Jupyter Notebook).

Data sinyal PPG yang diterima pada komputer kemudian melalui tahap *pre-processing* yang meliputi *bandpass filtering*, *smoothing*, dan segmentasi ke dalam *window* berdurasi 10 detik. Kualitas setiap *window* dievaluasi menggunakan indeks SSQI, sehingga hanya segmen sinyal dengan kualitas memadai yang digunakan pada tahap berikutnya.

Dari setiap *window* yang lolos seleksi kualitas, dilakukan ekstraksi fitur HR, fitur PRV pada domain waktu dan frekuensi, serta fitur statistik sinyal PPG. Fitur-fitur dari seluruh *window* pada satu subjek kemudian diagregasi secara statistik untuk membentuk satu vektor fitur tingkat subjek, yang digunakan sebagai masukan ke dalam model *Voting Ensemble*.

Model ML menghasilkan keluaran berupa status kondisi tekanan darah dan nilai kepercayaan prediksi, yang selanjutnya dikirimkan kembali ke mikrokontroler ESP32 dan diteruskan ke aplikasi Blynk melalui koneksi IoT untuk ditampilkan secara *near real-time* dalam bentuk status kondisi tekanan darah, HR, nilai *confidence*, dan kualitas sinyal.

Dengan alur tersebut, sistem mampu mengintegrasikan proses akuisisi data, pemrosesan sinyal, klasifikasi berbasis ML, dan visualisasi berbasis IoT secara *end-to-end*. Alur sistem kerja alat secara keseluruhan ditunjukkan pada Gambar 6.



Gambar 9. Bagan sistem kerja alat