

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

2.1.1 *Hypertension Detection Base on Photoplethysmography Signal Morphology and Machine Learning Techniques [5]*

Pada penelitian evdochim et. al (2022) mengusulkan metode mendeteksi hipertensi berbasis analisis morfologi sinyal photoplethysmography (PPG) dengan memperkenalkan ANC Test™. Metode ini mengklasifikasikan bentuk gelombang PPG ke dalam empat kelas morfologi, yaitu Anacrotic (A), Normal (N), Normal-Collapsing (NC), dan Collapsing (C). Selain parameter kelas morfologi, penelitian tersebut juga memanfaatkan fitur tambahan berupa Diastolic-to-Systolic Gradient Ratio (DtS) sebagai representasi numerik karakteristik gelombang PPG.

Fitur-fitur morfologi yang diperoleh kemudian digunakan sebagai masukan ke berbagai model pembelajaran mesin, termasuk Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Logistic Regression, Decision Tree, dan Ensemble Classifier. Hasil eksperimen menunjukkan bahwa kombinasi fitur tertentu mampu meningkatkan performa klasifikasi tekanan darah sistolik, dengan akurasi terbaik mencapai 67.1% pada Dataset 1 menggunakan Quadratic SVM. alaupun demikian, penelitian tersebut melaporkan bahwa performa model sangat dipengaruhi oleh kualitas sinyal PPG, variasi dataset, serta strategi pemilihan fitur morfologi.

ANC Test™ merupakan metode analisis morfologi sinyal PPG yang dikembangkan oleh Evdochim et al. Metode ini mengelompokkan bentuk gelombang PPG menjadi empat kategori, yaitu Anacrotic (A), Normal (N), Normal-Collapsing (NC), dan Collapsing (C), sehingga

perubahan morfologi pembuluh darah dapat digunakan sebagai indikator kondisi tekanan darah.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Penggunaan fitur morfologi sinyal PPG sebagai dasar untuk menganalisis hipertensi
- Pemanfaatan karakteristik gelombang *systolic peak* dan *diastolic peak* sebagai representasi kondisi tekanan darah.
- Penggunaan fitur numerik tambahan seperti *rasio gradien* (DtS) sebagai inspirasi dalam pemilihan fitur berbasis sinyal.
- Penggunaan model *machine learning* sebagai pendekatan klasifikasi.
- Penemuan bahwa performa model bergantung pada kualitas dan kombinasi fitur, sehingga mendorong penggunaan kombinasi fitur pada penelitian ini.

2.1.2 Photoplethysmogram-based Heart Rate and Blood Pressure Estimation with Hypertension Classification [8]

Pada penelitian ini dilakukan oleh Chowdhury et al (2024) yaitu mengembangkan estimasi tekanan darah dan klasifikasi hipertensi berbasis sinyal *photoplethysmography* (PPG) menggunakan pendekatan *machine learning* dan implementasi *hardware* berbasis FPGA. Pada penelitian ini, sinyal PPG yang digunakan untuk mengekstraksi fitur fisiologis yang berkaitan dengan tekanan darah, seperti karakteristik denyut jantung dan perubahan volume darah.

Hasil yang didapat pada penelitian ini menunjukkan sistem yang dikembangkan mampu mencapai akurasi klasifikasi hipertensi sebesar 92,42% dengan nilai kesalahan atau *error* (*Mean Absolute Error/MAE*)

sebesar 4.75 mmHg untuk *systolic blood pressure* dan 3.334 mmHg untuk *diastolic blood pressure*.

Pada penelitian ini juga menunjukkan bahwa fitur berbasis sinyal PPG, khususnya fitur morfologi memiliki kemampuan yang tinggi dalam hal mendeteksi hipertensi. Hal ini juga menjadi dasar bahwa fitur domain waktu seperti *systolic peak* dan *diastolic peak* paling relevan untuk digunakan pada penelitian ini.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Penggunaan sinyal PPG sebagai sumber utama dalam mendeteksi hipertensi.
- Pemanfaatan fitur domain waktu berbasis morfologi seperti *systolic peak* dan *diastolic peak*.
- Membuktikan bahwa fitur morfologi memiliki kemampuan yang tinggi dalam hal mendeteksi hipertensi.
- Penerapan *machine learning* untuk meningkatkan akurasi klasifikasi.
- Hasil akurasi yang tinggi menjadi dasar bahwa fitur domain waktu relevan untuk digunakan dalam penelitian ini.

2.1.3 *Estimating Blood Pressure from Photoplethysmogram Signal and Demographic Features using Machine Learning Techniques* [9]

Pada penelitian ini dilakukan oleh Shuzan et al. mengusulkan metode estimasi tekanan darah berbasis sinyal PPG dan fitur demografis dengan menggunakan algoritma *machine learning*. Penelitian ini, dilakukan dengan ekstraksi fitur berbagai domain, yaitu *time domain*, *frequency domain*, dan *time-frequency domain*.

Hasil yang didapat pada penelitian ini menunjukkan model *Gaussian Process Regression* (GPR) menghasilkan performa terbaik

dengan nilai RMSE sebesar 6.74 mmHg untuk *systolic* dan 3.59 mmHg untuk *diastolic*. Selain itu, pada penelitian ini menegaskan bahwa sinyal PPG memiliki karakteristik utama berupa *systolic peak* dan *diastolic peak* yang dapat digunakan untuk merepresentasikan tekanan darah.

Pada penelitian ini juga didukung penggunaan kombinasi fitur domain waktu dan frekuensi dalam meningkatkan performa sistem estimasi tekanan darah.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Penggunaan kombinasi fitur domain waktu dan domain frekuensi.
- Pemanfaatan fitur *systolic* dan *diastolic* sebagai karakteristik utama sinyal PPG.
- Bukti bahwa kombinasi fitur multi-domain dapat meningkatkan performa model.
- Penggunaan *machine learning* dalam estimasi tekanan darah.
- Pendekatan multi-domain menjadi dasar dalam perancangan fitur pada penelitian ini.

2.1.4 Estimation of Systolic and Diastolic Blood Pressure for Hypertension Identification from Photoplethysmography Signals [10]

Pada penelitian yang dilakukan oleh De Oliveira et al. mengembangkan model *deep learning* untuk estimasi tekanan darah dan klasifikasi hipertensi menggunakan sinyal PPG. Pada penelitian ini model yang diusulkan yaitu *Neural model of Blood Pressure* (NeuBP) yang mampu melakukan ekstraksi fitur secara otomatis tanpa memerlukan proses *feature engineering* manual.

Hasil yang didapat pada penelitian ini menunjukkan bahwa model yang dikembangkan mampu mencapai MAE sebesar 5.02 mmHg untuk *systolic* dan 3.11 mmHg untuk *diastolic*.

Pada penelitian ini juga menunjukkan bahwa sinyal PPG memiliki hubungan *non-linear* dengan tekanan darah, sehingga diperlukan metode analisis yang mampu menangkap kompleksitas tersebut seperti *deep learning*.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Pemahaman bahwa hubungan antara sinyal PPG dan tekanan darah bersifat *non-linear*.
- Pentingnya penggunaan model yang mampu menangani kompleksitas data.
- Pemanfaatan metode berbasis pembelajaran mesin sebagai pendekatan utama.
- Bukti bahwa sinyal PPG mengandung informasi yang cukup untuk estimasi tekanan darah.
- Menjadi dasar pemilihan model yang mampu menangani data *non-linear* seperti *random forest*.

2.1.5 Temporal Attention to Estimate Continuous Blood Pressure Using Photoplethysmography Signal [11]

Pada penelitian yang dilakukan oleh maqsood et al. (2025) mengusulkan pendekatan *deep learning* berbasis *temporal attention* untuk meningkatkan akurasi estimasi tekanan darah dari sinyal PPG. dalam penelitian ini juga digunakan berbagai jenis fitur termasuk fitur domain waktu dan domain frekuensi.

Hasil yang didapat pada penelitian ini juga menunjukkan bahwa model yang diusulkan mampu mencapai nilai MAE yang sangat

rendah yaitu sekitar 2-3 mmHg yang telah memenuhi standar internasional.

Pada penelitian juga menunjukkan bahwa penggunaan kombinasi fitur dan model *deep learning* yang lebih kompleks dapat meningkatkan performa secara signifikan.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Penggunaan kombinasi fitur domain waktu dan domain frekuensi dalam meningkatkan performa model.
- Bukti bahwa kompleksitas model dan fitur berpengaruh terhadap akurasi.
- Pendekatan analisis sinyal PPG berbasis data yang lebih komprehensif
- Hasil performa tinggi menjadi dasar bahwa kombinasi fitur yang sangat penting.
- Menjadi referensi bahwa integrasi fitur multi-domain dapat meningkatkan akurasi secara signifikan

2.1.6 Clinical Validation of Comprehensive time-and Frequency-Domain Photoplethysmography Features from a single-sensor system for non-invasive assessment of vascular load and systolic blood pressure [12]

Pada penelitian yang dilakukan oleh Lin et al. ini melakukan validasi klinis terhadap fitur domain waktu dan domain frekuensi dari sinyal PPG dalam mendeteksi hipertensi. Penelitian ini juga melibatkan 590 partisipan dan menggunakan berbagai fitur seperti *waveform shape* dan *harmonic ratio*.

Hasil yang didapatkan pada penelitian ini menunjukkan bahwa fitur domain waktu seperti *systolic* dan *diastolic* serta fitur domain

frekuensi menunjukkan perubahan yang signifikan terhadap peningkatan tekanan darah.

Pada penelitian membuktikan bahwa kombinasi fitur domain waktu dan frekuensi mampu memberikan informasi yang lebih lengkap dalam analisis hipertensi.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Memvalidasi bahwa fitur domain waktu dan domain fitur memiliki hubungan signifikan dengan hipertensi.
- Penggunaan fitur *waveform* dan karakteristik sinyal sebagai indikator tekanan darah.
- Bukti bahwa kombinasi fitur memberikan informasi yang lebih lengkap.
- Pendekatan berbasis data klinis sebagai penguat relevansi fitur.
- Menjadi dasar penggunaan kombinasi fitur pada penelitian ini.

2.1.7 *A benchmark for machine-learning based non-invasive blood pressure estimation using photoplethysmogram* [7]

Pada penelitian yang dilakukan oleh González et al. mengembangkan *benchmark* untuk membandingkan berbagai model *machine learning* dalam estimasi tekanan darah berbasis sinyal PPG. Penelitian ini membandingkan 11 model dengan berbagai pendekatan.

Hasil yang didapatkan pada penelitian ini menunjukkan bahwa fitur domain waktu memiliki performa yang lebih baik dibandingkan fitur domain frekuensi jika digunakan secara terpisah, namun kombinasi keduanya memberikan hasil yang optimal. Penelitian ini

juga memperkuat pentingnya penggunaan kombinasi fitur dalam meningkatkan akurasi.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Perbandingan performa fitur domain waktu dan domain frekuensi.
- Bukti bahwa fitur domain waktu lebih kuat jika digunakan sendiri.
- Temuan bahwa kombinasi fitur menghasilkan performa terbaik.
- Pentingnya evaluasi model dalam berbagai skenario.
- Menjadi dasar utama penggunaan kombinasi fitur untuk meningkatkan akurasi.

2.1.8 Photoplethysmography Features Correlated with Blood Pressure Change [14]

Pada penelitian yang dilakukan oleh elgendi et al. merupakan studi review yang dapat menganalisis berbagai fitur PPG yang berkorelasi dengan tekanan darah. Penelitian ini mengkaji 297 publikasi dan mengidentifikasi fitur-fitur penting yang sering digunakan.

Hasil yang didapatkan pada penelitian ini menunjukkan bahwa fitur domain waktu khususnya yang berkaitan dengan morfologi sinyal seperti *systolic* dan *diastolic* yang merupakan fitur paling penting sering digunakan dan memiliki korelasi tinggi terhadap tekanan darah. Penelitian ini memberikan dasar teoritis yang kuat dalam pemilihan fitur pada penelitian ini.

Beberapa poin acuan yang menjadi referensi pada penelitian sebagai berikut:

- Identifikasi fitur PPG yang memiliki korelasi tinggi terhadap tekanan darah.
- Penegasan bahwa fitur morfologi seperti *systolic* dan *diastolic* merupakan fitur paling relevan.
- Bukti dari studi literatur bahwa fitur domain waktu banyak digunakan dalam penelitian PPG.
- Dasar teoritis dalam pemilihan fitur pada penelitian ini.
- Menjadi landasan ilmiah dalam menentukan fitur yang digunakan.

Berdasarkan pada beberapa penelitian terdahulu, bahwa dapat disimpulkan sinyal PPG ini memiliki potensi yang besar dalam estimasi tekanan darah dan klasifikasi hipertensi. Fitur domain waktu seperti *systolic peak* terbukti memiliki hubungan fisiologis yang kuat dengan tekanan darah, sehingga ada banyak yang gunakan dalam berbagai penelitian.

Namun, beberapa penelitian ini menunjukkan bahwa penggunaan fitur domain waktu saja belum cukup untuk merepresentasikan kompleksitas sinyal PPG yang bersifat *non-linear*. Fitur domain frekuensi seperti *Power Spectral Density* (PSD) dapat memberikan informasi tambahan terkait distribusi energi sinyal.

Selain itu, berdasarkan sisi model metode *machine learning* tradisional seperti SVM dan *Random Forest* memiliki keterbatasan dalam menangkap pola kompleks. Begitu sebaliknya, model *deep learning* seperti CNN dan LSTM menunjukkan performa yang lebih baik karena mampu melakukan ekstraksi fitur secara otomatis.


Dengan begitu, dapat disimpulkan bahwa kombinasi fitur domain waktu dan domain frekuensi serta penggunaan model yang lebih kompleks dapat meningkatkan akurasi sistem klasifikasi hipertensi

2.2 Tinjauan Teori

2.2.1 Photoplethysmography (PPG)


Photoplethysmography (PPG) adalah teknik pengukuran optik non-invasif yang dapat digunakan untuk mengukur perubahan pada volume darah dalam jaringan mikro dengan memanfaatkan interaksi cahaya dan jaringan biologis. Pada prinsip dasarnya PPG merupakan penyerapan dan refleksi cahaya oleh hemoglobin dalam darah, sehingga perubahan volume darah akibat aktivitas jantung dapat direkam dalam bentuk sinyal.





Gambar 2. 1 Alat Photoplethysmography (PPG)[14][15]

Pada gambar 2.1 ditunjukkan perangkat PPG berupa *pulse oximeter* dan sensor PPG berbasis modul elektronik. Sensor tersebut bekerja menggunakan sumber cahaya LED dan *photodetector* untuk mendeteksi perubahan volume darah



Gambar 2. 2 Morfologi Sinyal Photoplethysmography (PPG)[5]

Pada gambar 2.2 morfologi sinyal PPG yang umumnya terdiri dari systolic peak sebagai puncak utama akibat kontraksi jantung dan dicrotic wave (gelombang diastolik) yang dipengaruhi oleh elastisitas

pembuluh darah. Pada penelitian Evdochim et al. (2022) morfologi sinyal PPG diklasifikasikan menjadi beberapa bentuk, yaitu Anacrotic (A), Normal (N), Collapsing (C), dan Normal-Collapsing (NC) yang digunakan untuk indikator dalam analisis hipertensi berbasis machine learning. Perubahan bentuk gelombang tersebut menunjukkan adanya hubungan antara karakteristik sinyal PPG dengan kondisi tekanan darah pasien.

Sinyal PPG pada umumnya diperoleh dengan menggunakan sensor yang terdiri dari sumber cahaya (LED) dan fotodetektor. Cahaya yang dipancarkan akan menembus pada jaringan kulit, kemudian sebagian cahaya akan diserap oleh darah dan sebagian lainnya dipantulkan kembali ke sensor. Intensitas cahaya yang diterima oleh fotodetektor akan berubah sesuai dengan volume darah yang mengalir lalu menghasilkan sinyal PPG.

Sinyal Photoplethysmography (PPG) terdiri menjadi dua komponen utama yaitu, komponen non-pulsatile (DC/ Direct Current) dan komponen pulsatile (AC/ Alternating Current). Komponen DC merepresentasikan perubahan sinyal yang berlangsung lambat dan dipengaruhi oleh berbagai faktor fisiologis, seperti respirasi, aktivitas sistem saraf otonom, temperatur tubuh, serta karakteristik jaringan biologis. Sementara itu, komponen AC berhubungan langsung dengan aktivitas denyut jantung dan perubahan volume darah akibat proses kontraksi serta relaksasi jantung. Pada komponen AC inilah yang umumnya digunakan dalam analisis sinyal PPG karena mengandung informasi penting terkait kondisi sistem kardiovaskular, termasuk perubahan tekanan darah dan elastisitas pembuluh darah.

Dalam satu siklus gelombang PPG, terdapat beberapa karakteristik morfologi penting yang sering dianalisis. Systolic Peak adalah puncak utama pada sinyal yang dihasilkan akibat peningkatan tekanan darah ketika jantung mengalami kontraksi (sistol) untuk memompa darah ke seluruh tubuh. Setelah systolic, sinyal akan mengalami penurunan dan

membentuk dicrotic notch, yang dimana titik transisi antara fase sistolik dan diastolik yang berkaitan dengan penutupan katup aorta serta perubahan dinamika aliran darah. Selanjutnya, muncul diastolic peak atau puncak sekunder yang terjadi akibat refleksi gelombang darah dari pembuluh perifer menuju pembuluh utama. Ketiga karakteristik tersebut memiliki hubungan erat dengan kondisi hemodinamik dan elastisitas pembuluh darah, sehingga sering digunakan sebagai dasar ekstraksi fitur dalam analisis hipertensi berbasis PPG.

Karakteristik diatas memiliki hubungan erat dengan kondisi fisiologis sistem kardiovaskular. Pada perubahan bentuk gelombang PPG, seperti peningkatan durasi sistolik atau penurunan amplitudo diastolik, dapat mengindikasikan adanya gangguan seperti hipertensi atau kekakuan pembuluh darah.

Selain itu, sinyal PPG memiliki sifat non-linear dan kompleks karena dipengaruhi oleh beberapa faktor fisiologis dan lingkungan. Oleh karena itu, analisis sinyal PPG memerlukan teknik pemrosesan sinyal dan ekstraksi fitur yang tepat untuk memperoleh informasi yang relevan.

2.2.2 Preprocessing Sinyal

Preprocessing adalah tahap awal dalam pengolahan sinyal PPG yang bertujuan untuk meningkatkan kualitas sinyal sebelum dilakukan ekstraksi fitur. Sinyal PPG mentah pada umumnya mengandung berbagai gangguan, seperti *baseline drift*, *noise* frekuensi tinggi, *motion artifact* akibat pergerakan saat proses akuisisi data. Oleh karena itu, preprocessing dibutuhkan agar karakteristik utama sinyal dapat direpresentasikan dengan lebih jelas.

Pada penelitian ini, preprocessing dilakukan melalui proses filtering dan normalisasi sinyal. Filtering digunakan untuk mengurangi noise dan mempertahankan komponen frekuensi yang relevan dari sinyal PPG, sedangkan normalisasi dilakukan untuk menyamakan skala amplitudo antar data sehingga distribusi sinyal menjadi lebih stabil. Proses

preprocessing yang baik sangat penting karena kualitas fitur yang dihasilkan sangat bergantung pada kualitas sinyal yang digunakan.

2.2.3 Bandpass Filter

Bandpass filter merupakan metode filtering yang digunakan untuk melewatkan sinyal pada rentang frekuensi tertentu dan meredam frekuensi di luar rentang tersebut. Pada penelitian ini digunakan *Butterworth Bandpass Filter* dengan rentang frekuensi 0.5–8 Hz, karena rentang tersebut mencakup frekuensi fisiologis denyut jantung manusia dan karakteristik utama sinyal PPG.

Penggunaan bandpass filter bertujuan untuk menghilangkan noise frekuensi rendah (*baseline drift*), meredam noise frekuensi tinggi, memperjelas bentuk gelombang PPG, serta meningkatkan akurasi dalam proses deteksi fitur seperti systolic peak dan diastolic peak. Proses filtering dilakukan menggunakan filter orde 3 berbasis metode Butterworth, karena memiliki respons frekuensi yang halus dan mampu meminimalkan distorsi sinyal.

Secara matematis, frekuensi cutoff yang digunakan pada penelitian ini dapat dituliskan sebagai berikut:

$$0.5 \leq f \leq 8 \text{ Hz}$$

Dengan rinci berikut:

0.5 Hz = batas frekuensi bawah (*low cutoff*)

8 Hz = batas frekuensi atas (*high cutoff*)

Setelah melakukan filtering, dilakukan proses normalisasi z-score untuk menstabilkan amplitudo sinyal menggunakan persamaan berikut:

$$x_{norm} = \frac{x - \mu}{\sigma}$$

dimana:

x_{norm} = nilai sinyal,

μ = rata-rata sinyal (*mean*),

σ = standar deviasi sinyal.

2.2.4 Ekstraksi Fitur

Pada ekstraksi fitur ini proses untuk mengubah sinyal PPG mentah menjadi representasi numerik yang dapat digunakan dalam analisis dan klasifikasi. Fitur yang digunakan dalam penelitian ini dapat dibagi menjadi dua kategori utama, yaitu *time domain*, dan *frequency domain*.

A. Fitur *Time Domain*

Pada fitur domain waktu diperoleh langsung dari bentuk gelombang PPG dan merepresentasikan karakteristik morfologi sinyal. Fitur yang digunakan yaitu:

1. *Systolic Peak*

Pada *systolic peak* ini puncak utama dalam sinyal PPG yang terjadi akibat kontraksi jantung. Lalu fitur ini menunjukkan tekanan maksimum dalam satu siklus denyut jantung.

2. *Diastolic Peak*

Pada *diastolic peak* ini puncak sekunder yang muncul setelah *systolic peak* akibat refleksi gelombang darah. Lalu fitur ini berkaitan dengan elastisitas pembuluh darah.

3. *Pulse Width*

Pada *pulse width* ini jarak waktu antara dua *systolic peak* berturut-turut. Lalu fitur ini menggambarkan durasi satu siklus jantung.

4. *Pulse Area*

Pada *pulse area* ini luas area di bawah kurva sinyal PPG dalam satu siklus. Lalu fitur ini menggambarkan volume darah yang mengalir.

Fitur domain waktu ini memiliki keunggulan dikarenakan mudah diinterpretasikan secara fisiologis dan memiliki korelasi langsung dengan tekanan darah.

B. Fitur *Frequency Domain*

Pada fitur domain frekuensi, informasi sinyal yang diperoleh dengan mentransformasikan sinyal PPG dari domain waktu ke domain frekuensi menggunakan metode *Power Spectral Density* (PSD). PSD digunakan untuk menggambarkan distribusi daya atau energi sinyal terhadap frekuensi sehingga dapat memberikan informasi metode *welch* yang merupakan pengembangan dari *periodogram* dengan membagikan sinyal menjadi beberapa segmen kemudian menghitung rata-rata spektrum daya dari setiap segmen. Secara matematis, PSD dapat dinyatakan sebagai berikut:

$$PSD(f) = \frac{1}{N \cdot f_s} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi f n} \right|^2$$

Dengan rincian sebagai berikut:

$PSD(f)$ = nilai *Power Spectral Density* pada frekuensi f

$x(n)$ = sinyal PPG pada sampel ke- n

N = jumlah sampel sinyal

f_s = frekuensi sampling (125 Hz)

j = bilangan imajiner ($\sqrt{-1}$)

f = frekuensi

Pada penelitian ini digunakan dua fitur domain frekuensi yang diperoleh dari hasil PSD yaitu:

PSD Mean : rata-rata nilai PSD yang menggambarkan distribusi energi rata-rata sinyal pada seluruh rentang frekuensi

$$PSD_{mean} = \frac{1}{N} \sum_{i=1}^N PSD_i$$

PSD Max : nilai PSD maksimum yang dapat menunjukkan energi terbesar yang muncul pada frekuensi tertentu.

$$PSD_{max} = \max(PSD_i)$$

Fitur domain frekuensi memberikan informasi tambahan mengenai kondisi fisiologis, yaitu perubahan hemodinamik dan kekakuan pembuluh darah yang berkaitan dengan hipertensi. Oleh karena itu, kombinasi fitur domain frekuensi dan domain waktu diharapkan mampu menghasilkan representasi sinyal PPG yang lebih lengkap untuk meningkatkan akurasi klasifikasi hipertensi.

C. Kombinasi Fitur

Penggunaan kombinasi fitur domain waktu dan frekuensi memberikan representasi yang lebih lengkap terhadap sinyal PPG. Fitur domain waktu menangkap karakteristik morfologi, sedangkan fitur domain frekuensi menangkap karakteristik spektral. Dengan demikian kombinasi kedua fitur ini diharapkan mampu meningkatkan performa sistem klasifikasi.

2.2.5 Machine Learning dan Deep Learning

Machine Learning merupakan metode pembelajaran berbasis data yang digunakan untuk melakukan klasifikasi atau prediksi berdasarkan fitur yang telah diekstraksi. Dalam konteks penelitian ini, *machine learning* digunakan untuk mengklasifikasikan kondisi hipertensi berdasarkan fitur sinyal PPG.

2.2.5.1 Decision Tree

Decision tree merupakan algoritma klasifikasi berbasis struktur *tree* atau pohon yang membagi data secara rekursif berdasarkan fitur.

a. Konsep dasar pada *decision tree*

Data dibagi menjadi node berdasarkan fitur terbaik hingga mencapai daun (*leaf*) yang merepresentasikan kelas.

b. Kriteria pemilihan split

$$\text{Entropy: } \text{Entropy}(s) = - \sum p_i \log_2 p_i$$

Information gain:

$$\text{Gain} = \text{Entropy}(\text{parent}) - \sum \frac{|\text{child}|}{|\text{parent}|} \text{Entropy}(\text{child})$$

Alternatif: gini index

$$\text{Gini} = 1 - \sum p_i^2$$

c. Algoritma

Memilih fitur terbaik (maksimal gain / meminimalkan gini), lalu bagi data berdasarkan fitur tersebut, ulangi hingga node homogen atau mencapai kedalaman maksimum

d. Proses klasifikasi

Data baru ditelusuri dari *root* hingga *leaf* berdasarkan aturan *split*

Algoritma Decision Tree dalam melakukan klasifikasi adalah sebagai berikut:

- ❖ Menginput dataset awal.
- ❖ Menghitung nilai entropy atau gini index untuk setiap fitur.
- ❖ Memilih fitur terbaik sebagai root node berdasarkan nilai gain tertinggi.
- ❖ Membagi dataset berdasarkan fitur tersebut.
- ❖ Mengulangi proses pembagian secara rekursif pada setiap cabang.
- ❖ Proses berhenti jika data sudah homogen atau mencapai batas tertentu.
- ❖ Untuk data baru, klasifikasi dilakukan dengan menelusuri pohon dari root ke leaf.

2.2.5.2 Random Forest (Ensemble learning)

Random forest adalah metode *ensemble* yang menggabungkan banyak *decision tree* untuk meningkatkan akurasi dan stabilitas.

a. Konsep dasar pada *random forest*

Model ini terdiri dari banyak pohon keputusan yang dilatih pada subset data yang berbeda.

b. Algoritma

Mengambil sampel data (*bootstrap sampling*), lalu membangun *decision tree* untuk setiap sampel, pilih

subset fitur secara acak pada setiap split, lalu ulangi untuk banyak *tree*.

c. Proses klasifikasi

Output yang ditentukan berdasarkan voting mayoritas:

Algoritma Random Forest dalam melakukan klasifikasi adalah sebagai berikut:

- Mengambil beberapa subset data secara acak dari dataset (bootstrap sampling). Membangun decision tree untuk setiap subset data. Pada setiap node, memilih subset fitur secara acak. Mengulangi proses hingga terbentuk banyak pohon.
- Untuk data uji, setiap pohon memberikan prediksi.
- Hasil akhir ditentukan berdasarkan voting mayoritas dari seluruh pohon.
- Dengan seiring berkembangnya teknologi, metode *deep learning* mulai banyak digunakan dalam analisis sinyal PPG. *Deep Learning* merupakan bagian dari *machine learning* yang menggunakan jaringan saraf tiruan untuk mempelajari representasi data secara otomatis.