

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Tanda Vital dan Pemantauannya Melalui Sinyal Fisiologis Tubuh**

Tanda vital adalah indikator penting yang mencerminkan kondisi fisiologis dasar tubuh manusia. Pemantauan tanda vital secara akurat dan berkelanjutan memiliki peran yang sangat penting dalam penilaian kesehatan, baik dalam konteks medis maupun penelitian. Setiap perubahan pada tanda vital ini dapat memberikan petunjuk awal adanya gangguan kesehatan atau kondisi patologis.

Seiring dengan perkembangan teknologi, pemantauan tanda vital kini tidak hanya terbatas pada pemeriksaan manual, tetapi juga dilakukan secara otomatis dengan menggunakan sinyal fisiologis tubuh. Sinyal fisiologis adalah data yang dihasilkan oleh aktivitas biologis tubuh, seperti sinyal listrik dari otot dan jantung, serta sinyal optik dari perubahan volume darah. Sinyal ini memungkinkan pengukuran tanda vital secara *real-time* dan non-invasif, yang mempermudah pemantauan kesehatan seseorang, baik di rumah sakit maupun di lingkungan rumah.

##### **2.1.1 Tanda Vital**

Tanda vital (*vital sign*) adalah serangkaian parameter fisiologis dasar yang mencerminkan kondisi kesehatan seseorang dan menggambarkan fungsi penting tubuh. Tanda vital mencakup empat parameter utama: detak jantung, tekanan darah, laju pernapasan, dan suhu tubuh (RSU Pindad, 2022). Pemantauan tanda vital sangat

penting untuk memastikan fungsi dasar tubuh berada dalam rentang normal, sehingga potensi gangguan kesehatan dapat diantisipasi dan dicegah.

Dalam pemantauan kesehatan, tanda vital sering diukur melalui analisis sinyal tubuh. Sinyal tubuh adalah data fisiologis yang dihasilkan dari aktivitas tertentu di dalam tubuh, seperti aliran darah atau impuls saraf. Parameter tanda vital dapat diukur secara non-invasif menggunakan perangkat medis atau teknologi *wearable*. Contohnya, sinyal denyut nadi yang direkam melalui *photoplethysmography* (PPG) dapat mencerminkan detak jantung sekaligus memberikan estimasi tekanan darah.

### **2.1.2 Sinyal Fisiologis**

Sinyal fisiologis adalah hasil dari aktivitas biologis tubuh manusia yang dapat direkam dan dianalisis untuk memperoleh informasi penting mengenai kondisi kesehatan. Jenis-jenis sinyal ini sangat beragam, tergantung pada sumbernya, dan dapat diklasifikasikan ke dalam beberapa kategori utama. Salah satu kelompok terbesar adalah sinyal bioelektrik, yaitu sinyal yang dihasilkan oleh aktivitas listrik dalam tubuh.

Contoh paling umum dari sinyal bioelektrik adalah elektrokardiogram (EKG), yang merekam aktivitas listrik jantung. Sinyal EKG dihasilkan dari perubahan potensial listrik akibat propagasi aksi potensial pada otot jantung selama siklus denyut jantung. Setiap detak jantung menghasilkan gelombang listrik yang khas (seperti gelombang P, Q, R, S, dan T), yang dapat dianalisis untuk menentukan kondisi fungsional jantung. Analisis lanjutan pada sinyal EKG sering kali digunakan untuk mendeteksi kelainan irama jantung atau perubahan kecil pada

gelombang yang berkaitan dengan aktivitas ventrikel jantung. Sinyal fisiologis lainnya mencakup (Bruce, 2015):

1. Elektromiogram (EMG): Aktivitas listrik otot.
2. Elektroretinogram (ERG): Aktivitas listrik retina mata.
3. Elektrogastrogram (EGG): Aktivitas listrik di saluran pencernaan.
4. Elektroensefalogram (EEG): Aktivitas listrik otak, yang sering digunakan untuk menganalisis pola tidur, tingkat kesadaran, dan fungsi neurologis.

Selain sinyal bioelektrik, terdapat jenis sinyal fisiologis lain yang tidak secara langsung berasal dari aktivitas listrik, seperti *photoplethysmogram* (PPG). Sinyal PPG adalah sinyal optik yang dihasilkan dari perubahan volume darah di pembuluh darah tepi. Perubahan volume darah ini memengaruhi penyerapan cahaya yang dipancarkan ke jaringan kulit, sehingga menghasilkan pola sinyal yang dapat digunakan untuk memantau aliran darah, detak jantung, dan parameter kardiovaskular lainnya. PPG termasuk sinyal fisiologis penting karena sifatnya yang *non-invasif*, mudah direkam, dan banyak digunakan dalam perangkat medis portabel.

## **2.2 Tekanan Darah dan Metode Pengukurannya**

Tekanan darah merupakan salah satu parameter penting dalam evaluasi tanda vital manusia yang mencerminkan kondisi fungsi jantung dan sirkulasi darah. Pengukuran tekanan darah tidak hanya memberikan informasi dasar tentang kesehatan kardiovaskular, tetapi juga membantu mendeteksi kondisi medis seperti hipertensi dan hipotensi. Dalam bidang klinis maupun penelitian, tekanan darah sering menjadi fokus utama karena relevansinya terhadap berbagai penyakit dan gangguan metabolisme.

Berbagai metode telah dikembangkan untuk mengukur tekanan darah, baik secara langsung maupun tidak langsung. Dengan berkembangnya teknologi, pendekatan non-invasif berbasis sinyal fisiologis, seperti *photoplethysmography* (PPG), telah menarik perhatian karena potensi penggunaannya untuk pemantauan tekanan darah secara berkelanjutan.

### 2.2.1 Tekanan Darah

Tekanan darah adalah ukuran tekanan yang dihasilkan oleh darah saat mengalir melalui arteri. Tekanan ini dipengaruhi oleh jumlah darah dalam pembuluh serta elastisitas dinding pembuluh darah (Mariati and Hepilita, 2020). Karena tekanan darah memberikan gambaran dasar tentang kesehatan, pengukurannya hampir selalu dilakukan dalam setiap pemeriksaan kesehatan. Tekanan darah diukur dengan dua angka yaitu tekanan sistolik dan tekanan diastolik, dengan satuan pengukuran dalam milimeter air raksa/Merkuri/*Hydrargyrum*/Hg (mmHg), dijelaskan sebagai berikut:

1. Tekanan Sistolik, adalah tekanan maksimum yang terjadi saat jantung memompa darah ke arteri selama fase sistol, dengan rata-rata sekitar 120 mmHg.
2. Tekanan Diastolik, adalah tekanan minimum saat jantung beristirahat di antara detak, biasanya sekitar 80 mmHg.

Kategori tekanan darah umumnya didefinisikan oleh organisasi kesehatan seperti *American College of Cardiology* (ACC), *American Heart Association* (AHA), dan *Joint National Committee 8* (JNC 8). Adapun kategori tekanan darah menurut JNC 8 yang merupakan salah satu *guideline* terbaru sebagai acuan di Indonesia sebagaimana terlihat pada Tabel 2.1 dan Tabel 2.2.

Tabel 2.1 Kategori Tekana Darah Berdasarkan Usia

Sumber: (Fauzi, 2022)

| Kategori Usia             | Normal          |                  |
|---------------------------|-----------------|------------------|
|                           | Sistolik (mmHg) | Diastolik (mmHg) |
| Dewasa (19-44 tahun)      | 90 - 120        | 60 – 80          |
| Lansia ( $\geq 60$ tahun) | < 140           | < 90             |

Tabel 2.2 Kategori Tekanan Darah

Sumber: (Fauzi, 2022)

| Kategori Tekanan Darah         | Tekanan Systolik (mmHg) | Tekanan Diastolik (mmHg) |
|--------------------------------|-------------------------|--------------------------|
| Tekanan Darah Rendah           | $\leq 90$               | $\leq 60$                |
| Pra-hipertensi                 | 120 -139                | 80 - 89                  |
| Hipertensi Stadium I           | 140 - 159               | 90 - 99                  |
| Hipertensi Stadium II          | 160 - 180               | 100 - 110                |
| Krisis Hipertensi              | > 180                   | > 110                    |
| Hipertensi Systolik Terisolasi | > 140                   | < 90                     |

Tekanan darah normal berdasarkan standar AHA dan JNC 8 adalah kurang dari 120/80 mmHg. Namun, nilai tekanan darah normal ini tidak berlaku untuk orang dengan kategori lanjut usia (lansia).

Pada Tabel 2.1, nilai tekanan darah normal untuk kategori usia dewasa (19-44 tahun) berada pada kisaran 90–120 mmHg untuk tekanan sistolik dan 60–80 mmHg untuk tekanan diastolik. Kemudian untuk kategori lansia ( $\geq 60$  tahun) <140 mmHg untuk tekanan sistolik dan <90 mmHg untuk tekanan diastolik (Nareza, 2020).

Nilai tekanan darah yang kurang atau melebihi nilai tekanan darah normal akan mengakibatkan terjadinya penyakit tekanan darah rendah (hipotensi) dan tekanan darah tinggi (hipertensi). Hipotensi dapat mengakibatkan terjadinya anemia, depresi, dan berbagai masalah serius lainnya. Sedangkan hipertensi dapat


mengakibatkan berbagai masalah kesehatan serius seperti penyakit jantung dan stroke (Fauzi, 2022). Tekanan darah tinggi memiliki empat kategori seperti yang terlihat pada Tabel 2.2 yaitu pra-hipertensi, hipertensi stadium I, hipertensi stadium II, dan krisis hipertensi. Selain beberapa kategori tersebut, terdapat penyakit hipertensi yang terjadi akibat nilai tekanan sistolik di atas 140 mmHg dan nilai tekanan diastolik di bawah 90 mmHg atau sering disebut dengan penyakit hipertensi sistolik terisolasi. Penyakit ini paling sering dialami oleh lansia di atas 60 tahun yang disebabkan karena arteri menjadi kaku seiring bertambahnya usia (Handayani, 2020).

### 2.2.2 Metode Pengukuran Tekanan Darah

Secara umum, metode pengukuran tekanan darah terbagi menjadi dua jenis (Zienkiewicz, 2017):

#### 1. Metode invasif

Pada metode ini, tekanan darah diukur dengan memasukkan kateter fleksibel berisi cairan dan sensor tekanan langsung ke dalam arteri, seperti ditunjukkan pada Gambar 2.1. Teknik ini sangat akurat, tetapi memiliki risiko, seperti infeksi dan pendarahan, karena melibatkan prosedur langsung ke dalam pembuluh darah.



Gambar 2.1 Skema Pengukuran Tekanan Darah Invasif

Sumber: (Beard and Ashton-Cleary, 2019)

## 2. Metode non-invasif

Metode ini lebih aman dan dapat digunakan secara rutin untuk mengukur tekanan darah tanpa perlu masuk ke dalam tubuh. Metode non-invasif yang paling umum adalah menggunakan *sphygmomanometer*, seperti yang terlihat pada Gambar 2.2. *Sphygmomanometer* mengukur tekanan darah dengan melingkarkan manset di lengan yang mengembang dan mengempis untuk membaca tekanan arteri (Mediastudents, 2018). Namun, alat ini hanya mengukur tekanan darah pada saat tertentu dan tidak dapat melakukan pemantauan terus-menerus.



Gambar 2.2 Pengukuran Tekanan Darah Menggunakan *Sphygmomanometer*

Sumber: (Mediastudents, 2018)

Sebagai alternatif, penelitian terbaru telah mengeksplorasi penggunaan sinyal PPG sebagai metode non-invasif untuk mengukur tekanan darah. Metode PPG ini dapat mengukur secara berkelanjutan tanpa manset. Namun, teknologi ini masih dalam tahap pengembangan dan belum seakurat metode lainnya. Tabel 2.3 merangkum kelebihan dan kekurangan dari masing-masing metode berikut.

Tabel 2.3 Kelebihan dan Kekurangan Metode Pengukuran Tekanan Darah

Sumber: (Zienkiewicz, 2017)

| Metode                                                    | Kelebihan                                            | Kekurangan                                                                                       |
|-----------------------------------------------------------|------------------------------------------------------|--------------------------------------------------------------------------------------------------|
| Pengukuran invasif dengan kateter                         | Akurat dan dapat mengukur secara berkelanjutan       | Risiko infeksi dan pendarahan                                                                    |
| Pengukuran non-invasif dengan <i>sphygmomanometry</i>     | Tidak ada efek samping serius                        | Mengukur hanya sesaat, tidak nyaman untuk penggunaan berkelanjutan, bisa mengganggu aliran darah |
| Pengukuran non-invasif dengan <i>photoplethysmography</i> | Tanpa manset, berkelanjutan, berpotensi dikembangkan | Akurasinya masih dalam tahap pengembangan                                                        |

### 2.3 *Photoplethysmography* (PPG) dan Prinsip Dasarnya

*Photoplethysmography* (PPG) merupakan teknik yang memainkan peran penting dalam pemantauan fisiologis karena kemampuannya merekam dinamika sirkulasi darah secara *real-time*. PPG tidak hanya berguna dalam analisis denyut jantung tetapi juga telah diterapkan dalam berbagai penelitian kesehatan untuk estimasi tekanan darah, oksigenasi darah, dan variabilitas detak jantung.

Pemahaman mendalam tentang prinsip kerja PPG menjadi hal yang penting, terutama untuk mengetahui bagaimana sinyal yang dihasilkan dapat merepresentasikan perubahan volume darah.

#### 2.3.1 *Photoplethysmography* (PPG)

*Photoplethysmography* adalah metode non-invasif untuk mengukur perubahan volume darah, yang digunakan untuk memantau aliran darah manusia. Menurut (Kyriacou, 2006), PPG adalah teknik optik non-invasif yang umum dipakai dalam studi dan pemantauan denyut jantung, karena dapat merekam perubahan volume darah di pembuluh darah tepi.

### 2.3.2 Prinsip Dasar PPG

Prinsip kerja PPG melibatkan pemancaran cahaya yang menembus kulit, kemudian sebagian cahaya tersebut diserap atau dipantulkan oleh jaringan darah. Cahaya yang telah dimodulasi ini kemudian diukur oleh fotodetektor.

Teori dasar PPG didasarkan pada hukum *Beer-Lambert*, yang menjelaskan pelemahan intensitas cahaya saat melalui media penyerap. Hukum ini menggabungkan dua prinsip (Abay and Kyriacou, 2022), yaitu:

1. Hukum *Beer*, menyatakan bahwa intensitas cahaya yang melewati larutan akan menurun seiring dengan peningkatan konsentrasi larutan atau panjang lintasan yang dilalui oleh cahaya tersebut. Namun, jika hasil perkalian antara konsentrasi dan panjang lintasan tetap konstan, maka intensitas cahaya yang ditransmisikan juga akan tetap sama.
2. Hukum *Lambert*, menyatakan bahwa intensitas cahaya yang berkurang saat melewati suatu media bersifat eksponensial. Penurunan intensitas ini sebanding dengan panjang lintasan optik yang ditempuh cahaya dan intensitas awal cahaya tersebut.

Dalam Hukum *Lambert*, intensitas cahaya yang melemah saat melewati media penyerap dengan ketebalan ( $x$ ) dinyatakan secara matematis sebagai:

$$\frac{dI}{dx} = -k_1 \cdot I \quad \dots\dots\dots (2.1)$$

Ketika intensitas cahaya ( $I$ ) diintegrasikan dengan batas tertentu, persamaannya menjadi:

$$\ln \left( \frac{I_t}{I_0} \right) = -k_1 \cdot d \quad \dots\dots\dots (2.2)$$

Menurut Hukum *Beer*, pelemahan cahaya tergantung pada konsentrasi (C) dari zat dalam medium, yang dijelaskan sebagai:


$$\ln \frac{I_t}{I_0} = -K \cdot d \cdot C \quad \dots\dots\dots (2.3)$$

Secara umum, absorbansi A cahaya dalam media dapat dituliskan sebagai:

$$A = \epsilon \cdot d \cdot C \quad \dots\dots\dots (2.4)$$

Dimana absorbansi A berkaitan langsung dengan intensitas cahaya I yang menurun saat melewati medium:

$$I_t = I_0 e^{-A} = I_0 e^{-\epsilon \cdot d \cdot C} \quad \dots\dots\dots (2.5)$$



Gambar 2.3 Skema Bentuk Gelombang PPG sebagai Fungsi Waktu

Sumber: (Tamura *et al.*, 2014)

Prinsip dasar PPG dapat dijelaskan menggunakan Hukum *Beer-Lambert* yang dimodifikasi. Dalam PPG, cahaya dengan panjang gelombang tertentu digunakan untuk memantau volume jaringan yang berdenyut selama siklus jantung yang terdiri dari dua tahap, sistol dan diastol. Perubahan volume jaringan ini mengakibatkan variasi daya serap cahaya, yang menghasilkan gelombang PPG berdenyut seirama dengan detak jantung. Pada Gambar 2.3, tampak bahwa intensitas PPG yang terekam (I) memiliki hubungan terbalik dengan daya serap cahaya (A) dalam jaringan. Cahaya yang tidak diserap akan diteruskan ke sensor optik (fotodioda) dan

diukur sebagai intensitas. Secara matematis, perbedaan absorbansi cahaya antara sistol ( $A_s$ ) dan diastol ( $A_d$ ) dapat dirumuskan menggunakan prinsip *Beer-Lambert* sebagai berikut:

$$A_{s\lambda} = \ln\left(\frac{I_{0\lambda}}{I_{s\lambda}}\right) = \epsilon_{\lambda} \cdot C_s \cdot l_{s\lambda} + G_{\lambda} \quad \dots\dots\dots (2.6)$$

$$A_{d\lambda} = \ln\left(\frac{I_{0\lambda}}{I_{d\lambda}}\right) = \epsilon_{\lambda} \cdot C_d \cdot l_{d\lambda} + G_{\lambda} \quad \dots\dots\dots (2.7)$$

Disini,  $I_s$  dan  $I_d$  adalah intensitas cahaya yang diteruskan selama sistol dan diastol, sementara  $C_s$  dan  $C_d$  adalah konsentrasi penyerap, serta  $l_s$  dan  $l_d$  merupakan panjang jalur cahaya melalui jaringan.

Pada Gambar 2.3 absorbansi lebih tinggi saat sistol ( $A_s > A_d$ ) sehingga cahaya yang diteruskan saat sistol lebih rendah ( $I_s < I_d$ ). Perbedaan absorbansi antara sistol dan diastol ( $\Delta A$ ) pada panjang gelombang tertentu dihitung sebagai:

$$\Delta A_{\lambda} = A_{s\lambda} - A_{d\lambda} = \epsilon_{\lambda} (l_{s\lambda} \cdot C_s - l_{d\lambda} \cdot C_d) \quad \dots\dots\dots (2.8)$$

Penelitian terbaru menunjukkan bahwa panjang jalur optik tidak banyak berubah antara sistol dan diastol (Chatterjee and Kyriacou, 2019). Dengan asumsi  $I_s \approx I_d = l$  dan perubahan konsentrasi absorbansi dinyatakan sebagai  $\Delta C = C_s - C_d$ , maka persamaannya menjadi:

$$\Delta A_{\lambda} = \epsilon_{\lambda} \cdot l \cdot \Delta C = \ln\left(\frac{I_{d\lambda}}{I_{s\lambda}}\right) \quad \dots\dots\dots (2.9)$$

Persamaan ini menunjukkan bahwa perubahan absorbansi dapat dihitung dengan membandingkan intensitas cahaya yang diteruskan saat sistol dan diastol.

### 2.3.3 Komponen Sinyal PPG

Berdasarkan efek absorptansi cahaya dalam jaringan yang berdenyut dan tidak berdenyut, intensitas sinyal PPG terbagi menjadi dua komponen utama: AC dan DC (Abay and Kyriacou, 2022). Kedua komponen ini dapat dilihat pada Gambar 2.3.

#### 1. Komponen AC (Arus Bolak-Balik)


Komponen AC dihasilkan dari penyerapan cahaya pada pembuluh darah arteri yang berdenyut, dan berubah seiring detak jantung. Komponen ini terbagi menjadi dua, fase naik (anakrotik) yang berkaitan dengan sistol dan fase turun (katakrotik) yang berkaitan dengan diastol. Pada orang sehat, komponen ini biasanya memiliki frekuensi lebih tinggi dari 0,5 Hz (30 bpm) (Park *et al.*, 2022).

#### 2. Komponen DC (Arus Searah)

Komponen DC bersifat kontinu dan berasal dari penyerapan cahaya pada jaringan tidak berdenyut, seperti kulit, otot, dan tulang. Gelombang DC ini dapat dipengaruhi oleh proses seperti pernapasan, aktivitas sistem saraf simpatik, dan termoregulasi, dengan frekuensi sekitar 0,1 Hz dan 0,1–0,5 Hz untuk frekuensi pernapasan (Park *et al.*, 2022).

### 2.3.4 Metode Pengukuran Sinyal PPG

Pada PPG, terdapat dua mode pengukuran (Abay and Kyriacou, 2022):



Gambar 2.4 Skema Mode Pengukuran Sinyal PPG: (a) Mode Transmisi, (b) Mode Refleksi

Sumber: (Moraes *et al.*, 2018)

### 1. Mode Transmisi

Pada mode ini, cahaya diteruskan langsung dari sumber ke detektor yang ditempatkan pada sisi berlawanan dari kulit, seperti ditunjukkan pada Gambar 2.4(a).

### 2. Mode Refleksi

Dalam mode ini, sumber cahaya dan detektor ditempatkan berdampingan. Cahaya yang masuk ke kulit sebagian akan dipantulkan kembali dan diterima oleh detektor di dekat sumber cahaya, seperti ditunjukkan pada Gambar 2.4(b).

## 2.4 Karakteristik dan Tantangan dalam Pengolahan Sinyal PPG

Pengolahan sinyal PPG merupakan salah satu bidang yang terus berkembang dalam aplikasi biomedis. Sinyal ini memiliki karakteristik unik yang dipengaruhi oleh sumber sinyal, metode pengukuran, serta parameter yang dapat diekstraksi darinya.

Namun, analisis sinyal PPG menghadapi berbagai tantangan teknis. Tantangan tersebut mencakup sensitivitas terhadap *noise*, perbedaan karakteristik individu, dan gangguan berupa artefak gerakan yang dapat mengurangi akurasi hasil analisis. Oleh karena itu, memahami karakteristik dasar dan tipe sinyal PPG sangat penting sebagai langkah awal untuk menentukan strategi pengolahan yang optimal.

### 2.4.1 Karakteristik Sinyal PPG

Sinyal PPG ideal adalah sinyal yang secara akurat mencerminkan perubahan volume darah di pembuluh tanpa adanya gangguan atau *noise*. Sinyal ini memiliki beberapa karakteristik utama:

1. Gelombang Puncak yang Jelas

Sinyal PPG memiliki puncak yang terlihat saat jantung berkontraksi (sistolik) dan berelaksasi (diastolik) (Elgendi, 2016). Sinyal murni akan menunjukkan puncak yang jelas dengan bentuk dan ukuran tertentu seperti tinggi, luas, dan lebar (Almarshad *et al.*, 2022).

2. Stabilitas Garis Dasar (*Baseline*)

Garis dasar (*baseline*) sinyal PPG dapat bergeser karena berbagai faktor, seperti pernapasan, yang memengaruhi volume darah dalam jaringan. Pada sinyal PPG yang ideal, garis dasar ini seharusnya relatif stabil dan hanya berubah seiring detak jantung, tanpa variasi yang besar (Pollreisz and TaheriNejad, 2022).

3. Konsistensi Frekuensi dan Amplitudo

Frekuensi dan amplitudo sinyal PPG idealnya konsisten dan tidak berubah secara tidak wajar, kecuali sebagai respons terhadap perubahan fisiologis. Frekuensi sinyal PPG dapat dipengaruhi oleh laju pernapasan yang memodulasi detak jantung, sementara amplitudo PPG bervariasi sesuai perubahan volume darah akibat kontraksi dan relaksasi jantung (Pollreisz and TaheriNejad, 2022). Komponen frekuensi PPG utama seharusnya terkonsentrasi pada kisaran 0,5–10 Hz (Li *et al.*, 2018).

Frekuensi sinyal PPG bervariasi tergantung sumbernya, namun sebagian besar penelitian sepakat bahwa rentang frekuensi utama PPG berkisar antara 0,5 Hz hingga 5 Hz. Penelitian oleh (Pollreisz and TaheriNejad, 2022) menyebutkan bahwa komponen utama sinyal PPG memiliki frekuensi dalam kisaran 0,5–5 Hz. Demikian juga, (Majeed *et al.*, 2019) melaporkan bahwa frekuensi gelombang pulsa PPG berada di kisaran 0,5–4 Hz. Berdasarkan berbagai penelitian tersebut, frekuensi sinyal PPG dalam rentang 0,5–5 Hz perlu dipertahankan selama pra-pemrosesan karena mengandung informasi penting dari sinyal.


#### 4. *Signal-to-Noise Ratio* (SNR)

*Signal-to-Noise Ratio* (SNR) pada sinyal PPG menunjukkan perbandingan antara kekuatan sinyal dan kekuatan *noise*. SNR yang lebih tinggi menandakan bahwa sinyal PPG lebih bersih dan akurat (Li *et al.*, 2018).

Mendapatkan sinyal PPG ideal cukup sulit karena sinyal ini sering diukur saat ada gerakan, sehingga mudah terpengaruh *noise* dari gerakan tersebut (Pollreisz and TaheriNejad, 2022).

### 2.4.2 Tipe Sinyal PPG


Setiap gelombang pulsa PPG terdiri dari dua fase, yaitu fase anakrotik (*anacrotic*) dan fase dikrotik (*catacrotic*), yang mencerminkan naik dan turunnya pola aliran darah dalam tubuh (Elgendi, 2020), hal tersebut ditunjukkan pada Gambar 2.5.



Gambar 2.5 Tipe Gelombang Pulsa PPG

Sumber: (Abay and Kyriacou, 2022)


Morfologi gelombang pulsa PPG dipengaruhi oleh faktor-faktor seperti detak jantung, ritme jantung, kekakuan arteri, dan tekanan darah. Sistem saraf otonom juga dapat memengaruhi bentuk gelombang, misalnya saat seseorang mengalami stres atau menderita penyakit tertentu. Gambar 2.6 menunjukkan perubahan bentuk gelombang PPG pada pasien sehat seiring bertambahnya usia.



Gambar 2.6 Kelas Bentuk Gelombang PPG Berdasarkan Usia

Sumber: (Abay and Kyriacou, 2022)

Pada individu muda (Kelas 1), gelombang PPG sering menunjukkan puncak diastolik yang jelas. Namun, seiring bertambahnya usia, puncak ini cenderung berkurang.




Gambar 2.7 Contoh Sinyal PPG Ideal dan Terpengaruh *Noise*

Sumber: (Abay and Kyriacou, 2022)

Sinyal PPG cukup rentan terhadap beberapa jenis *noise*, seperti *noise* akibat gerakan (*motion artifact*), gangguan listrik, serta *noise* berfrekuensi rendah dan tinggi, yang ditampilkan pada Gambar 2.7, menunjukkan: (a) sinyal PPG bersih, (b) sinyal dengan modulasi pernapasan, (c) sinyal dengan modulasi *baseline*, (d) sinyal dengan gangguan listrik, (e) sinyal dengan gangguan gerakan, dan (f) sinyal dengan gabungan *noise* dari berbagai sumber.

### 2.4.3 Tantangan Pengolahan Sinyal PPG

Pada sinyal PPG, terdapat tiga jenis *noise* yang dapat mengganggu informasi, yaitu *noise* akibat gerakan (*motion artifact*), pergeseran *baseline* (*baseline wandering*), dan hipoperfusi. Gambar 2.8 memperlihatkan contoh distorsi PPG yang disebabkan oleh masing-masing *noise* ini.



Gambar 2.8 Contoh distorsi PPG yang representatif akibat artefak gerakan, pengembaraan garis dasar, dan hipoperfusi (dari atas ke bawah)

Sumber: (Park *et al.*, 2022)

### 1. *Motion Artifact*

*Motion artifact* adalah *noise* utama dalam sinyal PPG yang muncul akibat gerakan tubuh, seperti menggerakkan tangan, berjalan, atau berlari. Studi (Majeed *et al.*, 2019) dan (Moraes *et al.*, 2018) menunjukkan bahwa frekuensi *noise* akibat gerakan ini biasanya berada di atas 0,1 Hz, sedangkan (Park *et al.*, 2022) menyatakan bahwa rentang frekuensinya adalah 0,01–10 Hz, yang dapat tumpang tindih dengan frekuensi utama PPG (0,5–5 Hz). Distorsi ini dapat mengganggu pendeteksian fitur utama dan berpotensi menyebabkan kesalahan diagnosis. Untuk mengatasi hal ini, artefak gerakan harus dihilangkan. Dalam penelitian (Park *et al.*, 2022) filter *high-pass* dengan frekuensi *cut-off* 0,15 Hz digunakan tanpa mengubah bentuk pulsa PPG, sehingga rasio komponen AC dan DC tetap ideal.

### 2. *Baseline Wandering*

Pergeseran *baseline* pada sinyal PPG umumnya disebabkan oleh pernapasan, dengan frekuensi antara 0,15 hingga 0,5 Hz (Park *et al.*, 2022). Menurut (Karavaev *et al.*, 2021) dan (Majeed *et al.*, 2019), rentang frekuensi

pernapasan ini berada di kisaran 0,04-1,6 Hz. Untuk menghilangkan pergeseran *baseline* ini, filter *high-pass* dapat digunakan. Namun, jika komponen AC dari sinyal PPG lebih rendah dari frekuensi *cut-off* filter, sinyal bisa mengalami distorsi.

### 3. Hypoperfusion

*Noise* hipoperfusi muncul ketika perfusi darah rendah, yang bisa disebabkan oleh tekanan darah rendah atau vasokonstriksi, dan mengganggu kualitas sinyal PPG (Park *et al.*, 2022). *Noise* ini dapat menyulitkan dalam memperoleh informasi penting, sehingga pengurangannya diperlukan agar hasil pengukuran lebih akurat.

Selain pengendalian *noise*, penting juga memperhatikan proses akuisisi sinyal PPG karena kualitas sinyal PPG, serta akurasi dan keandalan pengukuran tekanan darah, sangat bergantung pada proses akuisisi. Beberapa faktor yang perlu diperhatikan meliputi:

#### 1. Penempatan Sensor

Sensor PPG harus ditempatkan di area yang tepat, seperti jari atau pergelangan tangan, untuk mendapatkan sinyal yang akurat dari perubahan volume darah (Sun and Thakor, 2015).

#### 2. Kontak Kulit

Sensor harus memiliki kontak yang baik dengan kulit untuk memastikan sinyal yang stabil dan bebas *noise*. Hindari adanya celah cahaya atau udara antara sensor dan kulit (Sun and Thakor, 2015).

### 3. Pengurangan Gerakan

Gerakan tubuh dapat menyebabkan *noise* pada sinyal PPG, sehingga penting untuk tetap diam selama pengukuran (Sun and Thakor, 2015).

### 4. Kondisi Lingkungan

Lingkungan sekitar juga harus bebas dari gangguan cahaya dan suara yang dapat mengganggu sinyal PPG (Askarian, Jung and Chong, 2019).

### 5. *Sampling Rate*

*Sampling rate* harus disesuaikan untuk menangkap perubahan volume darah dengan tepat (Pelaez-Coca *et al.*, 2022).

Selain sinyal PPG, data parameter fisiologis lain juga diperlukan dalam metode kalibrasi berbasis populasi, seperti data morfologi PPG dan data demografis (usia, jenis kelamin, tinggi, berat) (Abay and Kyriacou, 2021).

## 2.5 Konsep Dasar Tahapan *Machine Learning*

Pemahaman mendalam mengenai setiap konsep tahapan ML penting sebagai landasan teoritis dalam penerapan *machine learning* untuk berbagai permasalahan. Tahapan-tahapan tersebut secara umum meliputi *problem statement* (perumusan masalah), *data collection* (pengumpulan data), *model selection* (pemilihan model), *model training* (pelatihan model), *model evaluation* (evaluasi model), dan *deploy model* (implementasi model) (Géron, 2019).

### 2.5.1. *Problem Statement* (Perumusan Masalah)

Tahap perumusan masalah merupakan langkah awal yang krusial dalam proyek *machine learning*. Pada tahap ini, isu atau kebutuhan yang ingin diselesaikan diidentifikasi dan didefinisikan secara jelas. Perumusan masalah yang

baik akan mengarahkan seluruh proses *machine learning*, mulai dari jenis data yang perlu dikumpulkan hingga metrik evaluasi yang relevan untuk mengukur keberhasilan solusi yang dibangun (Kenge, 2020). Kejelasan dalam mendefinisikan tujuan dan batasan masalah akan mempermudah pemilihan pendekatan dan algoritma *machine learning* yang tepat.

### **2.5.2. Data Collection (Pengumpulan Data)**

Pengumpulan data adalah tahap fundamental dalam *machine learning*. Kualitas dan kuantitas data yang digunakan secara signifikan mempengaruhi kinerja model yang dihasilkan (Roh *et al.*, 2019). Data yang relevan dengan masalah yang ingin diselesaikan perlu dikumpulkan dari berbagai sumber yang tersedia. Proses pengumpulan data harus mempertimbangkan aspek etika dan privasi, terutama jika melibatkan data sensitif. *Data collection* tidak hanya terbatas pada tindakan mengumpulkan data mentah. Ini merupakan proses yang lebih luas yang mencakup segala upaya untuk mendapatkan data yang sesuai dan siap untuk digunakan dalam pemodelan *machine learning*.

### **2.5.3. Model Selection (Pemilihan Model)**

Setelah data terkumpul, langkah selanjutnya adalah memilih model *machine learning* yang paling sesuai untuk tugas yang dihadapi. Terdapat berbagai jenis model *machine learning* yang dapat digunakan, tergantung pada jenis tugas (misalnya, klasifikasi, regresi, pengelompokan) dan karakteristik data. Untuk tugas regresi (memprediksi nilai kontinu), contoh model yang umum digunakan meliputi *Linear Regression*, *Support Vector Regression (SVR)*, *Random Forest Regression*, dan *Gradient Boosting Regression*. Untuk tugas klasifikasi (memprediksi kategori),

contohnya adalah *Logistic Regression*, *Support Vector Machines* (SVM), dan *Decision Trees*. Pemilihan model yang tepat memerlukan pemahaman tentang kekuatan dan kelemahan masing-masing algoritma serta kesesuaiannya dengan data dan tujuan pemodelan (Raschka and Mirjalili, 2017).

#### **2.5.4. Model Training (Pelatihan Model)**

Tahap pelatihan model adalah proses di mana algoritma *machine learning* belajar dari data yang telah dikumpulkan. Dalam proses ini, model menyesuaikan parameter internalnya berdasarkan pola yang ada dalam data pelatihan (*training data*) untuk meminimalkan kesalahan dalam memprediksi target variabel. Data seringkali dibagi menjadi set pelatihan dan set validasi (*validation set*). Set validasi digunakan untuk memantau kinerja model selama pelatihan dan membantu dalam proses *hyperparameter tuning* (menyesuaikan parameter yang tidak dipelajari oleh model secara langsung) serta mencegah *overfitting* (Raschka and Mirjalili, 2017).

#### **2.5.5. Model Evaluation (Evaluasi Model)**

Setelah model dilatih, penting untuk mengevaluasi kinerjanya menggunakan data yang belum pernah dilihat sebelumnya (set pengujian atau test set). Evaluasi bertujuan untuk mengukur kemampuan model dalam melakukan generalisasi terhadap data baru dan seberapa baik model tersebut mencapai tujuan yang ditetapkan dalam perumusan masalah (Raschka and Mirjalili, 2017). Metrik evaluasi yang digunakan akan bergantung pada jenis tugas *machine learning*. Untuk tugas regresi, metrik umum meliputi *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE). Untuk tugas klasifikasi, metrik seperti akurasi, presisi, dan recall sering digunakan (Little, 2019).

### 2.5.6. *Deploy Model (Implementasi Model)*

Tahap implementasi atau penyebaran (*deployment*) adalah proses mengintegrasikan model *machine learning* yang telah dievaluasi dan dianggap berhasil ke dalam sistem atau aplikasi yang sebenarnya. Bentuk implementasi dapat bervariasi, mulai dari integrasi ke dalam perangkat lunak, aplikasi web, perangkat mobile, hingga sistem embedded (Matlab Book Editors, 2018). Pertimbangan penting dalam tahap ini meliputi efisiensi komputasi model, skalabilitas, dan pemeliharaan model dalam jangka panjang. Pemantauan kinerja model setelah implementasi juga krusial untuk memastikan model tetap relevan dan akurat seiring waktu.

## 2.6 Pra-pemrosesan Sinyal PPG

Sinyal PPG sering kali dipengaruhi oleh berbagai gangguan, seperti *noise* dari gerakan, artefak pernapasan, atau fluktuasi *baseline* akibat faktor fisiologis. Untuk memastikan kualitas analisis dan akurasi hasil yang diinginkan, diperlukan langkah-langkah pra-pemrosesan guna meminimalkan gangguan tersebut. Pra-pemrosesan adalah tahap awal yang penting dalam pengolahan sinyal PPG untuk menghilangkan komponen yang tidak diinginkan, memperhalus data, serta menyelaraskan sinyal ke dalam rentang yang konsisten.

Pada tahap pra-pemrosesan, terdapat beberapa metode utama yang digunakan, seperti *detrending* untuk menghilangkan variasi *baseline*, *smoothing* menggunakan metode seperti filter *Savitzky-Golay* untuk memperhalus sinyal, dan normalisasi dengan metode *min-max* untuk menstandarkan nilai sinyal ke rentang tertentu. Proses ini tidak hanya meningkatkan keandalan sinyal tetapi juga

mempersiapkan data untuk analisis lebih lanjut, seperti ekstraksi fitur atau pengembangan model prediksi.

### 2.6.1 *Detrending*

*Detrending* adalah proses untuk menghilangkan komponen tren atau *baseline* yang tidak diinginkan pada sinyal. Hal ini penting untuk memastikan analisis sinyal fokus pada informasi utama yang relevan secara fisiologis. Dalam konteks sinyal fisiologis seperti PPG, *detrending* bertujuan menghapus fluktuasi frekuensi rendah yang disebabkan oleh perubahan tekanan darah, pernapasan, atau gerakan tubuh (Tarvainen, Ranta-aho and Karjalainen, 2002). Sinyal yang telah didetrend lebih mencerminkan variasi yang relevan, seperti komponen pulsasi akibat denyut jantung.

*Linear detrending* adalah metode umum yang menghapus tren *linear* dengan memodelkan sinyal asli  $y(t)$  menggunakan regresi *linear*, (Spencer, 2019):

$$y(t) = \beta_0 + \beta_1 t + \epsilon(t) \quad \dots\dots\dots (2.10)$$

di mana  $\beta_0$  adalah konstanta (intersep *baseline*),  $\beta_1$  adalah gradien tren *linear*, dan  $\epsilon(t)$  adalah residual atau sinyal yang telah didetrend.

Proses ini menghilangkan komponen tren  $(\beta_0 + \beta_1 t)$  dari sinyal, menghasilkan  $\epsilon(t)$ , yaitu sinyal tanpa tren yang lebih relevan untuk analisis.

*Linear detrending* sangat sesuai untuk sinyal stasioner atau yang menunjukkan pola *linear*, seperti *baseline* pada sinyal PPG. Tanpa proses ini, keberadaan tren dapat menyebabkan bias atau ketidakakuratan, misalnya dalam pengukuran interval antar denyut. Dalam MATLAB, *linear detrending* dapat

dilakukan menggunakan fungsi bawaan *detrend*, yang dirancang untuk menghilangkan tren *linear* atau polinomial.

Proses *detrending* meningkatkan kualitas sinyal PPG dengan menghapus komponen *baseline* yang tidak relevan. Hal ini mendukung analisis lanjut, seperti ekstraksi fitur atau estimasi parameter fisiologis. Sebagai contoh, dalam pengukuran denyut jantung, *detrending* membantu menonjolkan puncak-puncak utama sinyal PPG, sehingga interval waktu antar denyut dapat dihitung dengan lebih akurat.

### 2.6.2 Metode *Smoothing (Savitzky-Golay Filter)*

*Smoothing Savitzky-Golay* adalah teknik yang digunakan untuk menghaluskan sinyal atau data dengan mengurangi *noise* sambil mempertahankan fitur-fitur penting, seperti puncak dan lembah. Teknik ini bekerja dengan cara melakukan konvolusi sinyal dengan polinomial, untuk memperoleh kurva yang lebih halus tanpa menghilangkan informasi penting dalam data.

Metode ini pertama kali diperkenalkan oleh *Abraham Savitzky dan Marcel Golay* pada tahun 1964. Mereka mengusulkan penggunaan polinomial orde rendah untuk mendekati data dalam jendela geser. Polinomial ini digunakan untuk melakukan estimasi nilai yang lebih halus pada titik-titik di dalam jendela, sehingga hasilnya adalah sinyal yang lebih mulus tetapi tetap mempertahankan bentuk karakteristik asli data (Savitzky and Golay, 1964).

Metode *smoothing Savitzky-Golay* dipilih untuk pengolahan sinyal PPG karena keberhasilannya dalam mengurangi *noise* sekaligus mempertahankan tren utama sinyal. Meskipun belum ada referensi yang secara langsung menggunakan

metode ini untuk sinyal PPG, penelitian pada sinyal fisiologis lainnya seperti EKG, menunjukkan bahwa *Savitzky-Golay* efektif dalam menghaluskan sinyal dan mengurangi *noise*. Hal ini disebabkan oleh kesamaan sifat dasar antara sinyal EKG dan PPG, keduanya merupakan sinyal fisiologis yang mencerminkan aktivitas jantung dan sirkulasi darah serta dipengaruhi oleh berbagai faktor fisiologis dan eksternal.

Sebagai contoh, dalam penelitian (Hargittai, 2005) yang membahas penggunaan filter *Savitzky-Golay* untuk sinyal EKG, filter ini terbukti dapat memperbaiki kualitas sinyal dengan menjaga komponen penting, seperti puncak dan lembah sinyal, tanpa menyebabkan distorsi. Dengan mempertimbangkan kesamaan sifat antara sinyal PPG dan EKG serta keberhasilan filter *Savitzky-Golay* pada sinyal EKG, metode ini dipilih untuk pengolahan sinyal PPG, memberikan hasil yang memadai dalam mengurangi *noise* tanpa mengorbankan integritas informasi fisiologis.

### **2.6.3 Normalisasi *Min-Max***

Normalisasi *Min-Max* adalah teknik pra-pemrosesan data yang digunakan untuk menskalakan nilai-nilai data ke dalam rentang tertentu, umumnya antara 0 dan 1. Tujuan utama dari teknik ini adalah untuk mengurangi bias yang disebabkan oleh perbedaan skala antar fitur dalam set data, terutama ketika data yang digunakan memiliki rentang nilai yang sangat bervariasi. Teknik ini sangat penting dalam berbagai aplikasi, termasuk dalam analisis sinyal fisiologis, seperti sinyal PPG, di mana amplitudo sinyal dapat bervariasi tergantung pada faktor eksternal atau

individu. Proses normalisasi *Min-Max* dilakukan menggunakan rumus berikut, (Patro and sahu, 2015):

$$yX_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \dots\dots\dots (2.11)$$

di mana  $X_{norm}$  adalah nilai yang dinormalisasi,  $X$  adalah nilai asli, serta  $X_{min}$  dan  $X_{max}$  adalah nilai minimum dan maksimum dari set data.

Metode ini efektif dalam memastikan bahwa setiap fitur memiliki kontribusi yang sebanding dalam analisis atau model prediksi, tanpa ada satu fitur yang mendominasi akibat perbedaan skala yang besar. Namun, penting untuk diperhatikan bahwa normalisasi *Min-Max* sangat sensitif terhadap nilai *outlier*, yang dapat menyebabkan distorsi pada skala data jika tidak ditangani dengan hati-hati (Zhang *et al.*, 2020).

Normalisasi ini sangat berguna terutama saat data digunakan dalam algoritma pembelajaran mesin atau analisis sinyal yang sensitif terhadap skala fitur, seperti dalam pengolahan sinyal PPG untuk estimasi tekanan darah atau identifikasi detak jantung. Dengan normalisasi, model yang diterapkan dapat bekerja lebih efisien dan akurat, karena semua fitur berada pada skala yang seragam.

Beberapa penelitian juga menunjukkan bahwa normalisasi *Min-Max* penting dalam pemrosesan sinyal untuk meningkatkan kualitas analisis, terutama dalam sinyal fisiologis yang memiliki variasi amplitudo yang besar antar individu atau kondisi pengukuran. Misalnya, pada analisis sinyal EEG, EKG atau PPG, normalisasi *Min-Max* membantu menjaga konsistensi pengukuran dan meningkatkan stabilitas algoritma analisis (Shourie, Firoozabadi and Badie, 2018).

## 2.7 Analisis Kualitas Sinyal

Analisis kualitas sinyal merupakan tahapan penting untuk mengevaluasi sejauh mana proses pra-pemrosesan berhasil meningkatkan kualitas sinyal. Sinyal fisiologis, seperti PPG sering kali mengandung artefak, *noise*, atau komponen frekuensi rendah yang dapat mengganggu akurasi analisis. Oleh karena itu, analisis kualitas sinyal dilakukan untuk memastikan bahwa langkah-langkah pra-pemrosesan, seperti *detrending*, dan *smoothing*, telah efektif dalam mengurangi gangguan dan mempertahankan informasi yang relevan.

### 2.7.1 Uji Stasioneritas (*Kwiatkowski Phillips Schmidt Shin*)

Uji *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS) digunakan untuk mengevaluasi apakah suatu sinyal atau data bersifat stasioner, yakni memiliki karakteristik statistik yang konstan terhadap waktu. Dalam analisis sinyal fisiologis, stasioneritas penting karena memungkinkan penerapan algoritma yang memerlukan asumsi stasioner. Uji KPSS mendeteksi keberadaan unit *root* dalam data, yang mengindikasikan ketidakstasioneritas (Kwiatkowski *et al.*, 1992).

Dalam metode KPSS, hipotesis nol ( $H_0$ ) menyatakan bahwa data bersifat stasioner, sedangkan hipotesis alternatif ( $H_1$ ) menyatakan bahwa data tidak stasioner. Statistik uji dihitung berdasarkan fungsi autokorelasi residual, dan nilai p digunakan untuk memutuskan apakah  $H_0$  diterima atau ditolak.

### 2.7.2 Analisis Spektrum Frekuensi

Analisis spektrum frekuensi adalah metode untuk mengidentifikasi distribusi energi sinyal pada berbagai frekuensi. Transformasi *Fourier* sering digunakan untuk mentransformasikan sinyal dari domain waktu ke domain frekuensi,

memungkinkan analisis komponen frekuensi yang relevan. Dalam penelitian sinyal fisiologis, teknik ini membantu mengevaluasi efektivitas pra-pemrosesan, seperti penghapusan *noise* artefak (Elgendi *et al.*, 2013).

Hasil analisis spektrum memberikan wawasan tentang karakteristik sinyal sebelum dan sesudah pra-pemrosesan, seperti keberhasilan filter dalam menghilangkan *noise* tertentu atau mempertahankan komponen frekuensi utama.

### 2.7.3 *Signal to Noise Ratio* (SNR)

*Signal-to-Noise Ratio* (SNR) adalah metrik yang membandingkan kekuatan sinyal utama terhadap *noise*, dinyatakan dalam desibel (dB). Rumus SNR adalah (Semmlow, 2012):

$$\text{SNR} = 10\log_{10}\left(\frac{P_{\text{signal}}}{P_{\text{noise}}}\right) \dots\dots\dots (2.12)$$

di mana  $P_{\text{signal}}$  adalah daya sinyal, dan  $P_{\text{noise}}$  adalah daya *noise*.


Mengenai nilai batas SNR yang ideal, banyak penelitian menunjukkan bahwa untuk berbagai aplikasi, nilai SNR yang lebih tinggi dari 20 dB dianggap cukup baik untuk memastikan kualitas sinyal yang jelas dan dapat diproses dengan akurat (Candence, 2020). Nilai SNR ini menunjukkan bahwa sinyal yang diperoleh lebih dominan dibandingkan dengan *noise* yang ada. Dalam konteks sinyal biologis, seperti EKG atau PPG, nilai SNR yang cukup tinggi ini sangat penting untuk mendapatkan hasil analisis yang akurat dan dapat diandalkan. Sedangkan SNR di bawah 20 dB sering kali menandakan bahwa *noise* terlalu kuat, yang dapat mengaburkan sinyal asli dan mengurangi keandalan hasil pengolahan data.

## 2.8 Deteksi dan Identifikasi Puncak serta Lembah pada Sinyal PPG

Deteksi dan identifikasi puncak serta lembah pada sinyal PPG adalah langkah penting dalam analisis sinyal untuk mengekstraksi informasi fisiologis yang relevan. Puncak dan lembah pada sinyal PPG mencerminkan karakteristik penting dari gelombang nadi yang dapat digunakan untuk menghitung berbagai fitur kardiovaskular. Salah satu pendekatan yang efektif untuk deteksi dan identifikasi puncak dan lembah adalah menggunakan analisis perubahan gradien.

### 2.8.1 Analisis Perubahan Gradien

Gradien merupakan besaran yang menggambarkan laju perubahan suatu variabel terhadap variabel lain yang dikendalikan (Monk and Munro, 2021). Konsep ini menjelaskan seberapa cepat suatu garis mengalami kenaikan atau penurunan saat bergerak dari kiri ke kanan, sehingga diperlukan metode pengukuran untuk menentukannya (Sullivan, 2013).



Gambar 2.9 Ilustrasi Kemiringan Garis Nonvertikal


Sumber: (Sullivan, 2013)

Pada Gambar 2.9, konsep gradien dijelaskan melalui dua komponen utama, yaitu *run* dan *rise*. *Run* merupakan jarak horizontal yang ditempuh ke arah kanan, sedangkan *rise* adalah perubahan vertikal yang terjadi, baik naik maupun turun.

Kemiringan suatu garis (*slope*) dihitung sebagai rasio antara *rise* dan *run*, yang secara matematis dirumuskan sebagai (James Stewart., Lothar Redlin., 2011):

$$\text{Gradien} = \text{Slope} = \frac{\text{rise}}{\text{run}} = \frac{\Delta y}{\Delta x} = \frac{y_2 - y_1}{x_2 - x_1} \dots\dots\dots (2.13)$$

Gradien pada garis lurus dapat dihitung secara sistematis dengan membandingkan perubahan vertikal ( $\Delta y$ ) terhadap perubahan horizontal ( $\Delta x$ ). Rasio ini menunjukkan kemiringan garis dan dapat dihitung dengan akurat menggunakan prinsip-prinsip matematika.



Gambar 2.10 (a) *Concave Up* ( $y = x^2$ ), Gradien Meningkat dan (b) *Concave Down* ( $y = -x^2$ ), Gradien Menurun

Selain menentukan kemiringan garis, gradien juga digunakan dalam analisis kurva dan sifat konkavitasnya, seperti ditunjukkan pada Gambar 2.10. Jika gradien suatu fungsi meningkat seiring bertambahnya nilai  $x$ , maka kurva bersifat *concave up* (cekung ke atas), seperti fungsi  $y = x^2$ . Sebaliknya, jika gradien menurun, maka kurva bersifat *concave down* (cekung ke bawah), seperti fungsi  $y = -x^2$ . Analisis ini sangat penting dalam pemrosesan sinyal, karena memungkinkan identifikasi perubahan bentuk kurva yang dapat mencerminkan kondisi fisiologis pada sinyal PPG.


Gradien merujuk pada perubahan tingkat suatu fungsi terhadap variabel independen, dalam hal ini adalah waktu. Dalam konteks sinyal PPG, gradien digunakan untuk mengidentifikasi titik-titik perubahan pada sinyal, termasuk puncak dan lembah. Gradien pertama dari sinyal memberikan informasi mengenai laju perubahan nilai sinyal, sementara gradien kedua menunjukkan kelengkungan dari sinyal tersebut.

Puncak pada sinyal PPG sering kali terjadi pada titik-titik di mana gradien pertama berubah arah, yaitu ketika tanda gradien pertama beralih dari positif ke negatif (untuk puncak) atau negatif ke positif (untuk lembah). Penggunaan gradien pertama untuk mendeteksi puncak dan lembah pada sinyal PPG telah banyak diterapkan, dengan mendeteksi perubahan arah gradien pada titik-titik tertentu yang dikenal sebagai titik *fiducial* (Abay and Kyriacou, 2022). Sementara itu, gradien kedua digunakan untuk mengidentifikasi titik-titik yang lebih halus, seperti takik dikrotik yang terdeteksi pada analisis turunan kedua akibat bentuk puncak diastolik yang kurang jelas.

### **2.8.2 Deteksi Puncak dan Lembah dalam Analisis PPG**

Deteksi puncak dan lembah pada sinyal PPG dilakukan dalam beberapa langkah, dimulai dengan penyaringan sinyal untuk menonjolkan komponen PPG yang diinginkan. Setelah itu, calon puncak dan lembah diekstraksi dengan mengidentifikasi titik-titik di mana gradien pertama berubah tanda (Abay and Kyriacou, 2022). Penggunaan ambang batas (*thresholding*) dan analisis gradien ini sangat berguna untuk memperbaiki akurasi deteksi dalam menghadapi *noise* atau gangguan pada sinyal.

1. Mengidentifikasi Gelombang Pulsa Individu: Proses pertama dalam analisis sinyal PPG adalah mengidentifikasi gelombang pulsa individu. Langkah-langkah yang terlibat meliputi penyaringan sinyal, ekstraksi calon pulsa, dan deteksi puncak serta koreksi puncak untuk memastikan bahwa titik puncak teridentifikasi dengan benar (Vadrevu and Sabarimalai Manikandan, 2019).



Gambar 2.11 Titik Fiducial pada Sinyal PPG

Sumber: (Abay and Kyriacou, 2022)

2. Mengidentifikasi Titik Fiducial: Titik fiducial adalah titik-titik spesifik yang dapat diidentifikasi pada gelombang pulsa atau turunannya, yang mencakup *onset* pulsa, puncak sistolik, puncak diastolik, dan takik dikrotik Gambar 2.11. Deteksi titik fiducial ini sangat bergantung pada analisis gradien pada sinyal asli dan turunannya (Abay and Kyriacou, 2022).
3. Menghitung Fitur Gelombang Pulsa: *Pulse wave analysis* (PWA) adalah teknik yang digunakan untuk mengeksplorasi morfologi sinyal PPG dengan mengekstraksi fitur-fitur dari bentuk gelombang pulsa dan turunannya. Fitur-

fitur ini memberikan wawasan tentang kondisi kardiovaskular individu dan penting dalam berbagai aplikasi medis (Abay and Kyriacou, 2022).

Analisis perubahan gradien, baik melalui turunan pertama maupun kedua, memberikan dasar yang kuat untuk deteksi dan identifikasi puncak serta lembah pada sinyal PPG. Penggunaan metode ini memungkinkan akurasi yang tinggi dalam mengidentifikasi titik-titik penting pada sinyal PPG, yang pada gilirannya dapat digunakan untuk mengukur berbagai fitur kardiovaskular.

### 2.8.3 Fitur Amplitudo dan Waktu Sinyal PPG untuk Prediksi Tekanan

Fitur amplitudo dan waktu pada sinyal PPG untuk prediksi tekanan darah dihitung berdasarkan posisi titik-titik penting seperti *onset* (a), puncak sistolik (b), *dicrotic notch* (c), dan puncak diastolik (d).

#### 1. Amplitudo Sistolik (ASys)

$$ASys = S - DiaEnd \quad \dots\dots\dots (2.14)$$

di mana ASys adalah amplitudo sistolik,  $S$  adalah puncak sistolik,  $DiaEnd$  adalah akhir diastolik.

#### 2. Amplitudo Diastolik (ADia)

$$ADia = Dia - DiaEnd \quad \dots\dots\dots (2.15)$$

di mana ADia adalah amplitudo diastolik,  $Dia$  adalah puncak diastolik,  $DiaEnd$  adalah akhir diastolik.

#### 3. Crest Time (CT)

$$CT = tS - tOnset \quad \dots\dots\dots (2.16)$$

di mana CT adalah *crest time*,  $tS$  adalah waktu puncak sistolik,  $tOnset$  adalah waktu *onset*.

#### 4. Delta Time (delT)

$$\text{del}T = tD - tS \quad \dots\dots\dots (2.17)$$

di mana *delT* adalah *delta time*, *tD* adalah waktu puncak diastolik, *tS* adalah waktu puncak sistolik.

#### 5. Durasi Sistolik (TSys)

$$TSys = tDic - tOnset \quad \dots\dots\dots (2.18)$$

di mana *TSys* adalah durasi sistolik, *tDic* adalah waktu *dicrotic notch*, *tOnset* adalah waktu *onset*.

#### 6. Durasi Diastolik (TDia)

$$TDia = tDic - tDiaEnd \quad \dots\dots\dots (2.19)$$

di mana, *TDia* adalah durasi diastolik, *tDic* adalah waktu puncak diastolik, *tDiaEnd* adalah waktu akhir diastolik.

### 2.9 Hubungan antara Fitur PPG dan Tekanan Darah

Analisis fitur dari sinyal PPG, seperti *onset* (a), puncak sistolik (b), *dicrotic notch* (c), puncak diastolik (d), serta amplitudo sistolik (ASys), amplitudo diastolik (ADia), *Crest Time* (CT), *Delta Time* (delT) TSys, dan TDia, sangat berhubungan erat dengan pengukuran tekanan darah. Fitur-fitur ini dapat memberikan gambaran tentang dinamika tekanan darah selama siklus jantung, dan digunakan untuk membangun model prediksi tekanan darah.

1. *Onset* (a): *Onset* merupakan titik awal dari gelombang PPG, yang menandakan dimulainya siklus jantung. Waktu antara *onset* dan puncak sistolik (b) dapat memberikan informasi mengenai waktu yang dibutuhkan oleh darah untuk bergerak dari jantung ke arteri besar, yang dapat berhubungan dengan kecepatan aliran darah dan elastisitas arteri (Chowdhury *et al.*, 2020).

2. Puncak Sistolik (b): Puncak sistolik mencerminkan tekanan darah tertinggi selama kontraksi jantung. Waktu dan amplitudo puncak ini berhubungan langsung dengan tekanan darah sistolik, yang dipengaruhi oleh faktor-faktor seperti kekakuan arteri dan fungsi jantung (Charlton *et al.*, 2018).
3. *Dicrotic Notch* (c): Takik dikrotik adalah penurunan kecil pada gelombang setelah puncak sistolik, yang menunjukkan penutupan katup aorta dan perubahan aliran darah. Waktu antara puncak sistolik dan *dicrotic notch* memberikan informasi mengenai fase kontraksi ventrikel, serta elastisitas dan resistensi pembuluh darah (Charlton *et al.*, 2018).
4. Puncak Diastolik (d): Puncak diastolik mencerminkan tekanan darah terendah selama relaksasi jantung. Tekanan diastolik dipengaruhi oleh elastisitas arteri dan resistensi pembuluh darah (Charlton *et al.*, 2018).
5. Amplitudo Sistolik (ASys): Amplitudo sistolik mencerminkan besarnya tekanan darah maksimum yang tercapai selama kontraksi jantung dan berkaitan dengan volume darah yang dipompa keluar oleh jantung (Chowdhury *et al.*, 2020).
6. Amplitudo Diastolik (ADia): Amplitudo diastolik mencerminkan tingkat resistensi pembuluh darah selama fase relaksasi jantung (Chowdhury *et al.*, 2020).
7. *Crest Time* (CT): *Crest Time* memberikan indikasi mengenai kecepatan aliran darah di arteri, yang dipengaruhi oleh elastisitas pembuluh darah dan kondisi kardiovaskular secara keseluruhan (Elgendi, 2020).

8. *Delta Time* (delT): *Delta Time* mencerminkan waktu siklus jantung penuh. Durasi ini dapat dipengaruhi oleh laju denyut jantung dan tekanan darah rata-rata (Elgendi, 2020).
9. TSys: TSys menggambarkan fase kontraksi ventrikel terkait dengan kecepatan darah yang dipompa ke dalam sirkulasi arteri (Chowdhury *et al.*, 2020).
10. TDia: TDia mencerminkan durasi fase relaksasi ventrikel dan resistensi arteri yang mempengaruhi tekanan diastolik (Chowdhury *et al.*, 2020).

Tekanan darah sistolik dan diastolik dapat diprediksi berdasarkan analisis fitur-fitur di atas, yang secara langsung mencerminkan kondisi hemodinamik pada arteri dan fungsi jantung. Misalnya, nilai puncak sistolik (b) dan amplitudo sistolik (ASys) berhubungan dengan tekanan darah sistolik, sedangkan puncak diastolik (d) dan amplitudo diastolik (ADia) berhubungan dengan tekanan darah diastolik. Parameter waktu seperti *Crest Time* (CT), *Delta Time* (delT), TSys, dan TDia memberikan wawasan tambahan mengenai kecepatan aliran darah, elastisitas arteri, dan durasi fase-fase siklus jantung.

Penting untuk dicatat bahwa hubungan antara fitur-fitur PPG dan tekanan darah dapat dipengaruhi oleh faktor individu seperti usia, kebugaran kardiovaskular, dan kondisi medis lainnya. Oleh karena itu, analisis fitur PPG harus dilakukan dengan mempertimbangkan faktor-faktor ini untuk menghasilkan estimasi tekanan darah yang akurat.

## 2.10 Model Prediksi Tekanan Darah Berbasis PPG

*Regression Learner* MATLAB adalah alat yang disediakan oleh MathWorks untuk membangun, melatih, dan mengevaluasi model regresi secara visual menggunakan berbagai algoritma pembelajaran mesin. Alat ini memberikan kemudahan dalam eksplorasi data, pengoptimalan hiperparameter, dan validasi model menggunakan teknik seperti *cross-validation*, yang membantu menghindari *overfitting*. Selain itu, *Regression Learner* memungkinkan pengguna untuk menerapkan berbagai algoritma regresi yang cocok untuk analisis data fisiologis, seperti sinyal PPG, guna memprediksi parameter kardiovaskular seperti tekanan darah (MathWorks, 2023). Alat ini sangat berguna dalam aplikasi medis dan kesehatan untuk membangun model prediksi yang akurat dan dapat diandalkan.

Untuk mengevaluasi kinerja model yang telah dilatih, *Regression Learner* menyediakan berbagai metrik evaluasi. Metrik ini digunakan untuk mengukur seberapa baik model dalam memprediksi nilai target berdasarkan data yang tersedia.

### 2.10.1 Konsep Dasar Regresi dalam Pemodelan

Regresi adalah metode statistik untuk memodelkan hubungan antara variabel dependen (Y) dan satu atau lebih variabel independen (X) (James *et al.*, 2013). Dalam konteks prediksi tekanan darah dari sinyal PPG, X merupakan fitur-fitur sinyal PPG dan Y merupakan nilai tekanan darah (SBP/DBP dalam mmHg).

Regresi terbagi dua jenis yaitu regresi linier dan non-linier, dimana regresi linier tidak cocok untuk hubungan kompleks seperti sinyal PPG dan tekanan darah karena sifatnya yang non-linier dan multifaktoral (Teng and Zhang, 2003).

Sedangkan regresi non-linier mampu menangkap hubungan stokastik tanpa asumsi linieritas, dengan menggunakan metode seperti GPR dan *Ensemble*. Secara matematis, persamaan regresi linier sederhana sebagai berikut:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x \quad \dots\dots\dots (2.20)$$

di mana  $\hat{y}$  menunjukkan prediksi Y berdasarkan fitur-fitur yang digunakan (X). sedangkan  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  adalah intersep yang dikenal sebagai koefisien atau parameter model.

### 2.10.2 Pendekatan X-Y dalam Pemodelan

Pendekatan pemodelan regresi dalam penelitian ini menghubungkan variabel independen (X) berupa fitur sinyal PPG dengan variabel dependen (Y) nilai tekanan darah melalui tiga lapis hubungan yang saling terkait. Pada lapis fisiologis, fitur-fitur PPG seperti amplitudo sistolik (ASys) dalam satuan mV dan *crest time* (CT) dalam ms memiliki dasar biomedis yang kuat sebagaimana dijelaskan pada bagian 2.9. Dimana ASys berkorelasi dengan *pulse pressure* melalui hukum fisika hemodinamik, sedangkan CT mencerminkan kecepatan aliran darah arteri yang berbanding terbalik dengan tekanan sistolik. Lapis statistik kemudian mentransformasi hubungan ini melalui fungsi regresi  $Y = f(X) + \epsilon$  (James *et al.*, 2013), di mana model *Gaussian Process Regression* (GPR) dengan kernel *squared exponential* secara khusus dirancang untuk menangkap hubungan non-linier sekaligus mengakomodasi perbedaan satuan antar fitur melalui parameter *length-scale* ( $l$ ) yang mengkompensasi variasi dimensional (Rasmussen and C. K. I. Williams, 2006).

Proses transformasi satuan dari mV ke mmHg terjadi secara tidak langsung melalui mekanisme pembelajaran mesin berbasis data. Model tidak melakukan konversi satuan fisika langsung, melainkan mempelajari pola hubungan kuantitatif dari pasangan data latih yang berisi *mapping* antara fitur PPG (dalam berbagai satuan) dengan nilai tekanan darah referensi (dalam mmHg) (Chowdhury *et al.*, 2020). Sebagai contoh, ketika model mengamati pola konsisten dimana ASys 650 mV berkorespondensi dengan SBP 120 mmHg pada banyak subjek, maka model akan membangun hubungan prediktif tersebut.

Kekuatan pendekatan ini terletak pada kemampuannya mempertahankan interpretabilitas fisiologis sekaligus menangkap kompleksitas hubungan antar variabel. Ketika model memprediksi SBP 120 mmHg dari ASys 650 mV dan CT 180 ms, prediksi tersebut bukan hasil konversi satuan linier, melainkan kesimpulan statistik yang didasarkan pada pembelajaran pola data komprehensif yang telah dikalibrasi dengan pengukuran invasif.

### 2.10.3 *Ensemble Bagged Trees*

*Ensemble Bagged Trees* adalah teknik *ensemble learning* yang menggunakan metode *bootstrap aggregating* atau *bagging*. Teknik ini melibatkan pembentukan beberapa pohon keputusan dari subset data pelatihan yang diambil secara acak dengan penggantian (*resampling*). Setiap pohon memberikan prediksi independen, dan hasil akhir adalah prediksi rata-rata atau mayoritas dari pohon-pohon tersebut. *Bagging* secara signifikan meningkatkan akurasi model, mengurangi variabilitas, dan efektif dalam menangani data dengan *noise* tinggi atau hubungan *non-linear* (BREIMAN, 1996).

Mekanisme *bagged* melibatkan pembuatan beberapa himpunan bagian dari data pelatihan melalui pengambilan sampel acak dengan penggantian, memungkinkan setiap pohon untuk belajar dari kumpulan data yang berbeda (*sampling bootstrap*). Prediksi dari pohon individu digabungkan, biasanya melalui rata-rata (untuk regresi) atau pemungutan suara mayoritas (untuk klasifikasi), yang mengarah pada peningkatan kinerja keseluruhan (agregasi model) (Lee *et al.*, 2022).

#### **2.10.4 Gaussian Process Regression (GPR)**

*Gaussian Process Regression* (GPR) adalah metode nonparametrik berbasis Bayesian yang sangat efektif dalam menangkap hubungan kompleks antar data. GPR memodelkan data menggunakan fungsi kernel, yang pada kasus ini adalah kernel *Squared Exponential* untuk menangani hubungan halus dan kernel *Exponential* untuk perubahan yang lebih cepat (Rasmussen and C. K. I. W. Williams, 2006). Salah satu keuntungan besar dari GPR adalah kemampuannya untuk memberikan prediksi probabilistik, yang berarti model ini tidak hanya memberikan nilai prediksi tetapi juga tingkat ketidakpastian dari prediksi tersebut.

Dalam konteks prediksi tekanan darah, GPR dengan kernel *Squared Exponential* sangat efektif dalam menangkap pola-pola yang lebih halus dan *non-linear* yang ada pada hubungan antara fitur-fitur sinyal PPG dan tekanan darah (Chowdhury *et al.*, 2020). Model ini dipilih karena fleksibilitas dan kemampuannya dalam mengakomodasi berbagai jenis hubungan antara data dan variabel target.

#### **2.10.5 Metrik Evaluasi Kinerja Model Regresi**

Dalam analisis regresi, penting untuk mengevaluasi kinerja model yang digunakan untuk memprediksi variabel target. Metrik evaluasi ini memberikan

gambaran yang jelas tentang seberapa baik model dalam menggambarkan hubungan antara variabel *input* dan *output*. Beberapa metrik yang umum digunakan untuk menilai akurasi model regresi adalah *Root Mean Squared Error* (RMSE), *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan *R-squared* ( $R^2$ ). Setiap metrik memiliki keunggulan dan kegunaan yang berbeda, tergantung pada tujuan analisis dan karakteristik data. Pemahaman yang baik tentang metrik ini sangat penting untuk memilih model yang paling sesuai dalam aplikasi praktis, seperti pengukuran tekanan darah menggunakan sinyal PPG atau tugas prediksi lainnya.

#### 2.10.5.1 *Root Mean Squared Error* (RMSE)

*Root Mean Squared Error* (RMSE) adalah metrik yang mengukur akar kuadrat dari rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual. RMSE memberikan gambaran tentang seberapa besar kesalahan model dalam satuan yang sama dengan data yang diprediksi, sehingga memudahkan interpretasi dalam konteks aplikasi nyata. RMSE lebih sensitif terhadap kesalahan besar, membuatnya optimal untuk kesalahan terdistribusi normal (Hodson, 2022). Semakin kecil nilai RMSE, semakin baik performa model. RMSE memiliki satuan yang sama dengan target.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \dots\dots\dots (2.21)$$

di mana  $y_i$  adalah nilai aktual (data target),  $\hat{y}_i$  adalah nilai prediksi,  $n$  adalah jumlah sampel.

Rumus RMSE adalah akar kuadrat dari rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual. Semakin kecil perbedaan antara nilai prediksi dan nilai aktual, semakin kecil pula nilai RMSE.

Karena RMSE melibatkan kuadrat dari kesalahan, kesalahan besar (*outliers*) memberikan pengaruh yang lebih besar terhadap nilai RMSE. Ini berarti model yang meminimalkan RMSE cenderung lebih tepat dalam memprediksi nilai yang lebih dekat dengan nilai aktual dan tidak menghasilkan kesalahan yang besar. Model yang lebih baik umumnya menghindari kesalahan besar.

RMSE dihitung dalam satuan yang sama dengan data aktual (misalnya, mmHg untuk pengukuran tekanan darah). Oleh karena itu, RMSE dapat memberi tahu seberapa jauh rata-rata prediksi model dari nilai yang sebenarnya dalam unit yang relevan. Semakin kecil RMSE, semakin mendekati nilai prediksi dengan nilai aktual.

Dalam konteks regresi atau model prediksi, nilai RMSE yang kecil menunjukkan bahwa model dapat memprediksi nilai *output* dengan akurat, dan model tersebut cenderung memiliki fitur-fitur yang relevan dan teknik yang tepat dalam melakukan prediksi.

#### **2.10.5.2 Mean Squared Error (MSE)**

*Mean Squared Error* (MSE) adalah rata-rata dari kuadrat selisih antara nilai prediksi dan nilai aktual. Mirip dengan RMSE tetapi tanpa mengambil akar kuadrat. MSE memberikan gambaran tentang seberapa besar rata-rata kesalahan model, namun sensitif terhadap *outliers* karena adanya kuadrat pada selisihnya. MSE memberikan penalti yang lebih besar pada prediksi yang sangat salah, yang bisa

membuat model lebih sensitif terhadap kesalahan besar. MSE sering digunakan untuk menilai kesalahan model, dan seringkali dipilih sebagai fungsi *loss* dalam pelatihan model regresi (Chicco, Warrens and Jurman, 2021).

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \dots\dots\dots (2.22)$$

di mana  $y_i$  adalah nilai aktual (data target),  $\hat{y}_i$  adalah nilai prediksi,  $n$  adalah jumlah sampel.

Pada *Regression Learner*, MSE dihitung menggunakan data validasi, yaitu data yang tidak digunakan untuk melatih model tetapi digunakan untuk mengukur kinerja model pada data yang tidak dikenal. Satuan MSE sama dengan kuadrat satuan dari target variabel, misalnya jika target variabel adalah tekanan darah dalam mmHg, maka MSE memiliki satuan (mmHg)<sup>2</sup>. Nilai MSE yang lebih kecil menunjukkan bahwa rata-rata kesalahan kuadrat antara prediksi dan nilai aktual lebih kecil, yang berarti model lebih baik dalam memprediksi hasil.

#### 2.10.5.3 Mean Absolute Error (MAE)

*Mean Absolute Error* (MAE) adalah rata-rata selisih absolut antara nilai prediksi dan nilai aktual. MAE mengukur seberapa besar kesalahan prediksi tanpa memberikan bobot tambahan pada kesalahan yang lebih besar, seperti yang dilakukan RMSE. MAE lebih kurang sensitif terhadap *outlier* dibandingkan dengan RMSE, sehingga cocok untuk distribusi kesalahan Laplacian (Hodson, 2022). MAE memberikan interpretasi langsung tentang besarnya kesalahan rata-rata.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \dots\dots\dots (2.23)$$

di mana  $y_i$  adalah nilai aktual (data target),  $\hat{y}_i$  adalah nilai prediksi,  $n$  adalah jumlah sampel.

Satuan dari *Mean Absolute Error* (MAE) adalah satuan yang sama dengan data yang diprediksi atau diukur. Sebagai contoh, jika data yang diprediksi adalah tekanan darah dalam satuan mmHg, maka MAE akan memiliki satuan yang sama, yaitu mmHg.

MAE dianggap lebih robust terhadap *outliers* (nilai yang jauh dari data lain) dibandingkan RMSE karena cara perhitungannya. MAE menghitung selisih *absolut* antara nilai aktual dan nilai prediksi, yang berarti setiap kesalahan dihitung dengan cara yang sama, tanpa memberi bobot lebih pada kesalahan yang lebih besar.

Sebaliknya, dalam perhitungan RMSE, kesalahan dihitung dengan cara mengkuadratkan selisihnya. Ini berarti bahwa kesalahan yang lebih besar akan berkontribusi lebih besar terhadap nilai akhir RMSE. Dengan kata lain, RMSE lebih sensitif terhadap *outliers*, karena nilai kuadrat dari kesalahan yang besar akan sangat mempengaruhi hasil. Jika ada data yang sangat menyimpang, RMSE cenderung memberikan penalti lebih besar pada model, sedangkan MAE hanya akan menambah jumlah selisih *absolut* tanpa memperbesar pengaruh kesalahan besar tersebut.

Karena itu, MAE memberikan gambaran yang lebih stabil tentang kinerja model, terutama ketika ada data yang sangat menyimpang atau *outliers* dalam dataset. MAE tidak menganggap kesalahan besar sebagai masalah besar, sedangkan RMSE lebih memperhatikannya dan bisa memberikan hasil yang sangat tinggi jika ada beberapa *outlier* yang besar.

#### 2.10.5.4 *R-squared* ( $R^2$ )

*R-squared* ( $R^2$ ), juga dikenal sebagai koefisien determinasi, mengukur sejauh mana variabilitas dalam data yang dapat dijelaskan oleh model. Nilai  $R^2$  berkisar antara 0 dan 1, di mana nilai yang lebih tinggi menunjukkan bahwa model lebih baik dalam menjelaskan variasi data. Nilai  $R^2$  yang mendekati 1 menunjukkan model yang baik, sementara nilai yang mendekati 0 menunjukkan bahwa model tidak dapat menjelaskan variabilitas dalam data (Chicco, Warrens and Jurman, 2021).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \dots\dots\dots (2.24)$$

di mana  $y_i$  adalah nilai aktual (data target),  $\hat{y}_i$  adalah nilai prediksi,  $\bar{y}$  adalah rata-rata nilai aktual.

$R^2$  sering digunakan untuk mengevaluasi seberapa baik model regresi dapat mencocokkan data, dengan interpretasi yang mudah diakses dalam banyak aplikasi analisis data.  $R^2$  lebih informatif daripada RMSE, MAE, dan MSE, karena mengontekstualisasikan kinerja model relatif terhadap distribusi data.

#### 2.10.6 *Error dan Akurasi dalam Evaluasi Pengukuran Tekanan Darah*

Evaluasi kinerja sistem pengukuran tekanan darah berbasis sinyal *Photoplethysmography* (PPG) dilakukan dengan membandingkan hasil pengukuran dari modul non-invasif dengan alat invasif yang digunakan sebagai referensi. Beberapa metrik yang digunakan untuk mengevaluasi hasil pengukuran adalah *error* (kesalahan), *persentase error*, *mean absolute percentage error* (MAPE) dan akurasi.

### 2.10.6.1 *Error* (Kesalahan)

Error mengukur selisih antara nilai yang dihasilkan oleh pengukuran non-invasif dengan nilai yang diukur oleh alat invasif (*gold standard*). *Error* ini dapat dihitung menggunakan persamaan berikut (Islamudin *et al.*, 2024):

$$Error = |\hat{y}_i - y_i| \quad \dots\dots\dots (2.25)$$

di mana  $\hat{y}_i$  adalah nilai hasil pengukuran non-invasif,  $y_i$  adalah nilai hasil pengukuran invasif (*gold standard*).

*Error* ini memberikan gambaran tentang seberapa jauh hasil pengukuran non-invasif menyimpang dari nilai sebenarnya (*gold standard*).

### 2.10.6.2 *Persentase Error*

Persentase *error* ini mengindikasikan seberapa besar kesalahan yang terjadi dalam pengukuran, dinyatakan dalam persentase terhadap nilai referensi. Persentase *error* dapat dihitung menggunakan persamaan berikut (Islamudin *et al.*, 2024):

$$\%Error = \frac{Error}{y_i} \times 100\% \quad \dots\dots\dots (2.26)$$

### 2.10.6.3 *Mean Absolute Percentage Error* (MAPE)

*Mean Percentage Error* (MPE) adalah metrik yang mengukur rata-rata persentase kesalahan antara nilai prediksi dan nilai aktual untuk seluruh dataset. MPE dapat dihitung menggunakan persamaan berikut (Chicco, Warrens and Jurman, 2021):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left( \frac{|\hat{y}_i - y_i|}{y_i} \right) \times 100\% \quad \dots\dots\dots (2.27)$$

di mana  $y_i$  adalah nilai aktual (data target),  $\hat{y}_i$  adalah nilai prediksi,  $n$  adalah jumlah sampel.

#### 2.10.6.4 Akurasi

Akurasi mengukur seberapa dekat hasil pengukuran non-invasif dengan nilai referensi (*gold standard*). Akurasi dapat dihitung menggunakan persamaan berikut (Islamudin *et al.*, 2024):

$$\%Akurasi = 100\% - \%Error \quad \dots\dots\dots (2.28)$$

Akurasi ini menunjukkan persentase kedekatan hasil pengukuran non-invasif terhadap nilai referensi. Semakin tinggi nilai akurasi, semakin akurat sistem pengukuran yang dikembangkan.

### 2.11 Perangkat SWADETEC



Gambar 2.12 Perangkat SWADETEC

Sumber: (Gunawan, Andang and Ridwan, 2023)

Dalam penelitian (Gunawan, Andang and Ridwan, 2023), SWADETEC adalah sistem elektronik berbasis sensor MAX30102 yang dirancang untuk mengukur sinyal vital tubuh, khususnya detak jantung. Sensor MAX30102 menggunakan cahaya tampak dengan panjang gelombang 650–670 nm untuk mendeteksi perubahan intensitas cahaya yang dipantulkan oleh darah melalui kulit.

Sistem ini diaplikasikan untuk pengukuran sinyal pada ujung jari dan pergelangan tangan, dua lokasi yang umum digunakan untuk mendeteksi sinyal PPG.

Sensor MAX30102 memiliki dua LED (merah dan inframerah) yang bekerja dengan fotodioda untuk mengukur intensitas cahaya yang diterima setelah dipantulkan atau ditransmisikan melalui kulit dan pembuluh darah. Sensor ini memiliki sensitivitas tinggi dan mampu memproses sinyal dengan resolusi ADC 18-bit. Data yang diperoleh dari sensor kemudian diproses menggunakan metode *detrend* untuk menghilangkan gangguan seperti osilasi akibat gerakan atau *noise* eksternal.

Penempatan sensor pada pergelangan tangan dipilih sebagai alternatif dari ujung jari untuk meningkatkan kenyamanan pengguna Gambar 2.12. Dalam implementasinya, sensor MAX30102 diintegrasikan dengan mikroprosesor ESP32 pada perangkat LILYGO®TTGO, yang berfungsi untuk membaca, memproses, dan menampilkan data. Pengukuran dilakukan pada 15 responden dan menunjukkan bahwa sinyal PPG yang diukur pada pergelangan tangan memiliki tingkat akurasi 85% dibandingkan dengan sinyal dari ujung jari.

## 2.12 Penelitian Terkait

Tabel 2.4 Penelitian Terkait (*State of the Art*)

| Identitas Penelitian                                                                                                        | Judul                                                                                                       | Permasalahan                                                                                                                           | Metode                                                                                                                                                                        | Hasil                                                                                                                                                                                  |
|-----------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| M. Kachuee, A. N. R. M. R. K. M. A. and J. A. (IEEE Transactions on Biomedical Engineering, 64(4), pp. 859–869, 2016).      | <i>Cuffless Blood Pressure Estimation Algorithms for Continuous Health-Care Monitoring</i>                  | Pengukuran tekanan darah konvensional menggunakan manset membutuhkan alat yang besar dan tidak praktis untuk pemantauan terus-menerus. | Pengembangan algoritma untuk estimasi tekanan darah tanpa manset berdasarkan sinyal PPG yang diolah dengan teknik pemrosesan sinyal dan pembelajaran mesin.                   | Algoritma yang dikembangkan dapat mengestimasi tekanan darah secara akurat tanpa menggunakan manset, membuka potensi untuk pemantauan kesehatan yang lebih mudah dan tidak mengganggu. |
| C. El-Hajj and P.A. Kyriacou (Biomedical Signal Processing and Control, 70, p. 102984, 2021).                               | <i>Cuffless blood pressure estimation from PPG signals and its derivatives using deep learning models</i>   | Metode pengukuran tekanan darah tanpa manset yang masih kurang akurat dan efisien dalam konteks aplikasi medis berbasis PPG.           | Penggunaan model <i>deep learning</i> untuk estimasi tekanan darah dari sinyal PPG dan turunannya, memanfaatkan jaringan saraf untuk meningkatkan akurasi estimasi.           | Pendekatan <i>deep learning</i> memberikan hasil yang lebih akurat dan dapat diandalkan untuk estimasi tekanan darah dibandingkan dengan metode konvensional.                          |
| A. Chakraborty, S. Ghosh, A. Roy, and A. Das (IEEE Transactions on Instrumentation and Measurement, 70(c), pp. 1–10, 2020). | <i>Measurement of Arterial Blood Pressure through Single-Site Acquisition of Photoplethysmograph Signal</i> | Sulitnya pengukuran tekanan darah arteri secara <i>non-invasif</i> dengan akurasi yang cukup menggunakan sinyal PPG.                   | Pengembangan teknik untuk mengukur tekanan darah arteri menggunakan pengambilan sinyal PPG dari satu titik tubuh dan teknik pemodelan matematis untuk estimasi tekanan darah. | Teknik yang diusulkan menunjukkan hasil yang menjanjikan dengan estimasi tekanan darah yang cukup akurat meskipun hanya menggunakan satu titik pengambilan sinyal.                     |

| Identitas Penelitian                                                                            | Judul                                                                                                                                                            | Permasalahan                                                                                                                                               | Metode                                                                                                                                                                                      | Hasil                                                                                                                                                                                       |
|-------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| S. Chatterjee and P.A. Kyriacou (Sensors (Switzerland), 19(4), p. 789, 2019).                   | <i>Monte carlo analysis of optical interactions in reflectance and transmittance finger photoplethysmography</i>                                                 | Kesulitan dalam memahami interaksi optik yang terjadi dalam pengukuran sinyal PPG, terutama untuk aplikasi dalam <i>finger photoplethysmography</i> .      | Analisis <i>Monte Carlo</i> digunakan untuk menyimulasikan interaksi optik dalam pengukuran reflektansi dan transmisi pada fotoplethysmogram jari untuk mendapatkan wawasan lebih mendalam. | Analisis ini memberikan pemahaman lebih baik tentang bagaimana interaksi optik mempengaruhi kualitas sinyal PPG yang diperoleh, yang dapat membantu meningkatkan desain sensor PPG.         |
| S. Maqsood, M. I. U. Ali, R. S. Khan, and A. Hussain (IEEE Access, 9, pp. 138817–138833, 2021). | <i>A Benchmark Study of Machine Learning for Analysis of Signal Feature Extraction Techniques for Blood Pressure Estimation Using Photoplethysmography (PPG)</i> | Tantangan dalam memilih teknik ekstraksi fitur yang optimal untuk estimasi tekanan darah menggunakan sinyal PPG dengan penerapan <i>machine learning</i> . | Studi benchmarking berbagai teknik ekstraksi fitur sinyal PPG dan penerapan berbagai algoritma <i>machine learning</i> untuk menentukan metode terbaik dalam estimasi tekanan darah.        | Studi ini mengidentifikasi teknik ekstraksi fitur yang paling efektif, serta memberikan rekomendasi algoritma <i>machine learning</i> terbaik untuk estimasi tekanan darah berdasarkan PPG. |
| S. Hargittai (Computers in Cardiology, 32, pp. 763–766, 2005).                                  | <i>Savitzky-Golay least-squares polynomial filters in ECG signal processing</i>                                                                                  | Tantangan dalam pemrosesan sinyal EKG yang terkontaminasi noise dan distorsi, yang dapat mempengaruhi hasil diagnosis medis.                               | Penggunaan filter polinomial <i>Savitzky-Golay</i> dalam pemrosesan sinyal EKG untuk mengurangi <i>noise</i> dan meningkatkan kualitas sinyal.                                              | Filter <i>Savitzky-Golay</i> efektif dalam memperbaiki kualitas sinyal EKG, meningkatkan akurasi analisis dan diagnosis berbasis sinyal jantung.                                            |

| Identitas Penelitian                                                                                            | Judul                                                                                                                                                  | Permasalahan                                                                                                                                             | Metode                                                                                                                                                                                          | Hasil                                                                                                                                                                                                          |
|-----------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| P.H. Charlton, S. J. A. H. I. J. (Physiological Measurement, 37(4), pp. 610–626, 2016).                         | <i>An assessment of algorithms to estimate respiratory rate from the electrocardiogram and photoplethysmogram</i>                                      | Pengukuran laju pernapasan secara akurat dari sinyal EKG dan PPG masih menjadi tantangan, terutama untuk aplikasi kesehatan berbasis perangkat portable. | Evaluasi dan perbandingan beberapa algoritma untuk memperkirakan laju pernapasan dari sinyal EKG dan PPG, dengan fokus pada akurasi dan ketepatan estimasi.                                     | Penelitian ini menunjukkan bahwa gabungan sinyal EKG dan PPG dapat memberikan estimasi laju pernapasan yang lebih akurat dibandingkan dengan penggunaan satu jenis sinyal saja.                                |
| D. Kwiatkowski, P.C.B. Phillips, P. Schmidt, dan Y. Shin (Journal of Econometrics, 54(1–3), pp. 159–178, 1992). | <i>Testing the null hypothesis of stationarity against the alternative of a unit root. How sure are we that economic time series have a unit root?</i> | Masalah dalam analisis time series ekonomi yang dapat dipengaruhi oleh masalah unit root, yang bisa menyesatkan hasil analisis stasioneritas.            | Pengembangan uji statistik untuk menguji hipotesis nol tentang stasioneritas dalam time series ekonomi, menggunakan uji Kwiatkowski-Phillips-Schmidt-Shin (KPSS).                               | Uji KPSS menunjukkan kemampuan yang lebih baik dalam mendeteksi stasioneritas dalam time series dibandingkan dengan uji unit root tradisional, memberikan dasar yang lebih kuat untuk analisis data ekonomi.   |
| M. Elgendi, S. M. M. A. H. (PLoS ONE, 8(10), pp. 1–11, 2013).                                                   | <i>Systolic Peak Detection in Acceleration Photoplethysmograms Measured from Emergency Responders in Tropical Conditions</i>                           | Deteksi puncak sistolik pada sinyal PPG akselerasi yang diukur dalam kondisi darurat dan lingkungan tropis dengan adanya gangguan eksternal.             | Pengembangan algoritma untuk mendeteksi puncak sistolik dari sinyal PPG akselerasi yang diukur oleh responder darurat, dengan mempertimbangkan kondisi lingkungan yang dapat mengganggu sinyal. | Algoritma yang dikembangkan dapat mendeteksi puncak sistolik dengan baik meskipun terdapat banyak gangguan yang dihadapi dalam pengukuran di lapangan, menunjukkan potensi teknologi ini dalam aplikasi medis. |

| Identitas Penelitian                                                                                              | Judul                                                                                                                          | Permasalahan                                                                                                                                               | Metode                                                                                                                                                                                    | Hasil                                                                                                                                                                                                                           |
|-------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| S. Vadrevu dan M. S. Manikandan (IEEE Transactions on Instrumentation and Measurement, 68(3), pp. 807–817, 2019). | <i>A Robust Pulse Onset and Peak Detection Method for Automated PPG Signal Analysis System</i>                                 | Deteksi onset dan puncak denyut nadi yang robust pada sinyal PPG masih menjadi tantangan, terutama pada sinyal yang terkontaminasi <i>noise</i> .          | Pengembangan metode deteksi onset dan puncak denyut nadi yang lebih robust untuk sistem analisis sinyal PPG otomatis, menggunakan pemrosesan sinyal untuk meningkatkan keandalan deteksi. | Metode ini memberikan hasil yang lebih akurat dalam deteksi onset dan puncak denyut nadi pada sinyal PPG, bahkan dalam kondisi sinyal yang terkontaminasi <i>noise</i> , meningkatkan aplikasi klinis dan pemantauan kesehatan. |
| P.H. Charlton, M. J. A. (IPEM, 2018).                                                                             | <i>Assessing mental stress from the photoplethysmogram: a numerical study</i>                                                  | Penilaian stres mental yang efektif melalui sinyal fisiologis seperti PPG masih belum optimal dan memerlukan teknik yang lebih baik dalam analisis sinyal. | Analisis numerik untuk mengevaluasi bagaimana PPG dapat digunakan untuk mendeteksi stres mental dengan memeriksa parameter yang terkait dengan perubahan fisiologis selama stres.         | Penelitian ini menunjukkan bahwa sinyal PPG dapat digunakan untuk menilai stres mental dengan teknik analisis yang tepat, membuka jalan untuk aplikasi di bidang kesehatan mental.                                              |
| M.H. Chowdhury, A. M. U. R. K. T. S. K. (Sensors (Switzerland), 20(11), p. 13127, 2020).                          | <i>Estimating blood pressure from the photoplethysmogram signal and demographic features using machine learning techniques</i> | Estimasi tekanan darah yang akurat menggunakan sinyal PPG dan informasi demografis menggunakan pendekatan machine learning.                                | Penggunaan teknik machine learning untuk memanfaatkan sinyal PPG bersama dengan data demografis untuk memperkirakan tekanan darah.                                                        | Metode ini menunjukkan hasil yang akurat dalam estimasi tekanan darah, dan model berbasis machine learning dapat diandalkan untuk aplikasi pemantauan kesehatan jangka panjang.                                                 |

| Identitas Penelitian                                                           | Judul                                                                                                                                                    | Permasalahan                                                                                                              | Metode                                                                                                                                               | Hasil                                                                                                                                                                                                           |
|--------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| T.O. Hodson, Geoscientific Model Development, 15(14), pp. 5481–5487, 2022.     | <i>Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not</i>                                                               | Memilih metrik yang tepat untuk mengukur kesalahan model prediksi antara RMSE dan MAE.                                    | Penulis membahas kapan sebaiknya menggunakan RMSE atau MAE, tergantung pada sifat data dan model yang digunakan.                                     | Penelitian ini menunjukkan bahwa RMSE lebih sensitif terhadap outlier dan cocok digunakan ketika kesalahan besar perlu diberi bobot lebih, sedangkan MAE lebih stabil dan tidak terpengaruh oleh nilai ekstrim. |
| D. Chicco, M.J. Warrens, G. Jurman, PeerJ Computer Science, 7, pp. 1–24, 2021. | <i>The coefficient of determination <math>R</math>-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation</i> | Menganalisis metrik evaluasi regresi terbaik antara $R$ -squared dan metrik lain seperti SMAPE, MAE, MAPE, MSE, dan RMSE. | Penulis melakukan perbandingan antara $R$ -squared dan metrik kesalahan lain untuk menilai model regresi.                                            | $R$ -squared memberikan gambaran yang lebih informatif mengenai sejauh mana variabel independen menjelaskan variabilitas data dibandingkan dengan metrik lainnya.                                               |
| L. Breiman, Risks, 24, pp. 123–140, 1996.                                      | <i>Bagging predictors</i>                                                                                                                                | Peningkatan akurasi model prediksi dengan menggabungkan prediksi dari beberapa model menggunakan teknik bagging.          | Breiman memperkenalkan teknik <i>Bootstrap Aggregating (bagging)</i> untuk mengurangi varians dan meningkatkan ketahanan model terhadap overfitting. | <i>Bagging</i> berhasil meningkatkan akurasi model, terutama pada model yang kurang stabil seperti pohon keputusan.                                                                                             |

| Identitas Penelitian                                                                                                         | Judul                                                                                                                             | Permasalahan                                                                                                                | Metode                                                                                                                          | Hasil                                                                                                                                                                        |
|------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Y. Lee, S. Kim, M. Lee, 2022.                                                                                                | <i>Not Just Explain, but Explain Well: Interpretable Machine Learning Based on Ensemble Trees</i>                                 | Pentingnya interpretabilitas dalam model machine learning dan bagaimana ensemble trees dapat membantu meningkatkan hal ini. | Penulis mengusulkan metode baru untuk meningkatkan interpretabilitas dalam model berbasis ensemble trees.                       | Pendekatan ini meningkatkan pemahaman pengguna terhadap keputusan model, yang sangat penting dalam aplikasi medis dan sosial.                                                |
| R. Gunawan, A. Andang, M. Ridwan, Journal of Biomimetics, Biomaterials and Biomedical Engineering, 59(1), pp. 131–143, 2023. | <i>Performance Comparison for Heart Rate Signal Detection for Different location in Fingertip and Wrist Using Sensor MAX30102</i> | Perbandingan kinerja deteksi sinyal detak jantung pada lokasi tubuh yang berbeda menggunakan sensor MAX30102.               | Penulis melakukan uji coba deteksi sinyal detak jantung pada ujung jari dan pergelangan tangan menggunakan sensor PPG MAX30102. | Hasil penelitian menunjukkan bahwa pergelangan tangan memberikan deteksi yang lebih akurat dibandingkan dengan ujung jari, meskipun terdapat gangguan noise di kedua lokasi. |
| Identitas Penelitian: T. Tamura, S. Sato, K. Imai, Electronics, 3(2), pp. 282–302, 2014.                                     | <i>Wearable photoplethysmographic sensors—past and present</i>                                                                    | Perkembangan sensor fotoplethysmografi (PPG) yang dapat dikenakan dan aplikasi pemantauannya dalam kesehatan.               | Penulis meninjau berbagai sensor PPG <i>wearable</i> dan aplikasinya dalam pemantauan kesehatan.                                | PPG <i>wearable</i> telah berkembang pesat, memungkinkan pemantauan detak jantung dan tekanan darah secara <i>real-time</i> dengan kualitas yang lebih baik.                 |
| J. Park, C. Lee, S. Choi, Frontiers in Physiology, 12(March), pp. 1–23, 2022.                                                | <i>Photoplethysmogram Analysis and Applications: An Integrative Review</i>                                                        | Analisis sinyal PPG dan aplikasinya dalam pemantauan kesehatan, dari detak jantung hingga tekanan darah.                    | Penulis mengulas berbagai metode dan aplikasi analisis sinyal PPG dalam konteks kesehatan.                                      | PPG efektif digunakan untuk pemantauan kesehatan, namun tantangan dalam mengurangi noise dan meningkatkan akurasi masih ada.                                                 |

| Identitas Penelitian                                                                                | Judul                                                                                     | Permasalahan                                                                                                                          | Metode                                                                                                                                                                                | Hasil                                                                                                                                                                                                    |
|-----------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| M.P. Tarvainen, P.O. Ranta-aho, P.A. Karjalainen, Biomedical Engineering, 50(4), pp. 254–261, 2002. | <i>An advanced detrending method with application to HRV analysis</i>                     | Evaluasi kinerja sinyal fotoplethysmografi (PPG) dalam pemantauan detak jantung.                                                      | Penelitian ini menganalisis efektivitas sinyal PPG dalam memantau detak jantung pada berbagai kondisi.                                                                                | PPG terbukti efektif dalam pemantauan detak jantung, dengan ketepatan yang tinggi terutama pada kondisi stabil.                                                                                          |
| H. Zhang, S. Wang, X. Li, Journal of Biomedical Informatics, 106(July 2019), p. 103427, 2020.       | <i>Multi-modal interactive fusion method for detecting teenagers psychological stress</i> | Menilai bagaimana stres psikologis pada remaja dapat dideteksi dengan menggunakan berbagai sumber data fisiologis secara bersamaan.   | Penulis mengembangkan metode fusi interaktif multi-modal untuk menggabungkan data dari beberapa sensor, seperti sinyal jantung dan PPG, guna mendeteksi stres psikologis pada remaja. | Metode fusi ini terbukti meningkatkan akurasi deteksi stres jika dibandingkan dengan menggunakan hanya satu jenis data, dan menunjukkan potensi besar dalam aplikasi pemantauan kesehatan mental remaja. |
| S.G.K. Patro, K.K. Sahu, Iarjset, pp. 20–22, 2015.                                                  | <i>Normalization: A Preprocessing Stage</i>                                               | Memahami pentingnya normalisasi dalam tahap pra-pemrosesan data untuk meningkatkan performa model machine learning dan analisis data. | Penulis membahas berbagai metode normalisasi, termasuk normalisasi <i>min-max</i> dan <i>z-score</i> , serta penerapannya dalam data yang akan dianalisis lebih lanjut.               | Normalisasi data sangat penting untuk menghindari bias akibat perbedaan skala antar fitur, yang dapat mempengaruhi hasil analisis atau model prediksi.                                                   |