

BAB II

TINJAUAN PUSTAKA

A. Penelitian Terdahulu

Penelitian mengenai deteksi tekanan darah tanpa kontak fisik atau *non-invasive* semakin berkembang pesat dalam beberapa tahun terakhir, Salah satu pendekatan yang cukup menarik dan mendapatkan banyak perhatian adalah penggunaan citra wajah sebagai sumber data untuk memprediksi tekanan darah seseorang, Teknologi *deep learning* menjadi metode utama dalam pengolahan citra dan ekstraksi fitur penting dari wajah, seperti perubahan warna kulit mikro yang berhubungan dengan aliran darah.

Penelitian oleh (Chen et al., 2023) menunjukkan bahwa penggunaan metode *remote photoplethysmography* (rPPG) yang dipadukan dengan CNN (*Convolutional Neural Network*) dapat meningkatkan akurasi estimasi tekanan darah dari wajah, Penelitian ini menggunakan video wajah untuk menangkap sinyal rPPG, yang kemudian diproses menggunakan jaringan saraf untuk mengestimasi tekanan darah sistolik dan diastolik.

Studi lain oleh (W. Liu et al., 2024) mengembangkan model *multi-task learning* yang tidak hanya memprediksi tekanan darah, tetapi juga detak jantung dan kadar oksigen dalam darah, Dengan menggunakan dataset wajah yang diambil dari kamera RGB standar, mereka berhasil menunjukkan bahwa model *deep learning* mampu memberikan hasil prediksi yang cukup akurat meskipun tanpa peralatan medis.

(Chen et al., 2023) dalam penelitiannya menggunakan *3D convolutional neural network* untuk mengekstrak fitur spasial-temporal dari video wajah,

Hasilnya menunjukkan peningkatan signifikan dalam akurasi dibandingkan metode 2D CNN biasa, karena 3D CNN mampu menangkap dinamika sinyal aliran darah dari waktu ke waktu.

Penelitian oleh (Nagar et al., 2024) fokus pada peningkatan kualitas sinyal rPPG menggunakan *spatial attention mechanism*, Pendekatan ini memungkinkan jaringan saraf untuk lebih fokus pada area wajah yang kaya akan informasi vaskular, seperti dahi dan pipi, sehingga hasil prediksi tekanan darah menjadi lebih presisi.

Dalam konteks implementasi sistem nyata (Feng et al., 2022) mengembangkan prototipe aplikasi berbasis smartphone yang mampu merekam wajah pengguna dan memprediksi tekanan darah secara real-time, Meskipun masih dalam tahap pengembangan awal, studi ini menunjukkan potensi besar dari integrasi teknologi AI dan perangkat mobile untuk pemantauan kesehatan secara mandiri.

Selain itu, (Jeyakumar et al., 2017) mengevaluasi keandalan sistem berbasis wajah dalam berbagai kondisi pencahayaan dan sudut kamera, Mereka menyimpulkan bahwa model deep learning dapat dilatih agar lebih robust terhadap gangguan lingkungan, sehingga tetap memberikan hasil yang stabil.

(Hwang & Lee, 2024) melakukan penelitian dengan memanfaatkan sinyal PPG dan rPPG yang kemudian diproses menggunakan jaringan saraf konvolusional (CNN). Hasil penelitian mereka menunjukkan bahwa estimasi tekanan darah menggunakan sinyal fisiologis non-invasif dapat dicapai dengan error yang relatif kecil, meskipun masih memerlukan pengujian lebih luas untuk aplikasi klinis.

(Qiao et al., 2022) memperkenalkan sistem *ReViSe (Remote Vital Signs Measurement)* yang menggunakan kamera smartphone untuk mengukur tanda vital termasuk tekanan darah. Dengan memanfaatkan *deep learning*, mereka berhasil mencapai akurasi yang cukup tinggi, dengan nilai *Mean Absolute Error (MAE)* pada tekanan darah sistolik dan diastolik masing-masing 6–9 mmHg. Akan tetapi, penelitian tersebut masih dilakukan pada kondisi pencahayaan yang sangat terkontrol sehingga tantangan di lapangan belum sepenuhnya terjawab.

(Hwang & Lee, 2024) mengembangkan metode *Phase-Shifted rPPG*, yang menekankan pada pemrosesan fase sinyal untuk memperkirakan tekanan darah. Hasil penelitian mereka menunjukkan bahwa metode berbasis fase mampu meningkatkan ketahanan sistem terhadap variasi frekuensi sinyal. Namun, metode ini sensitif terhadap gerakan kepala sehingga penggunaannya di lingkungan bebas gerakan masih menjadi kendala.

(Akamatsu et al., 2024) menghadirkan model *U-FaceBP* berbasis *Bayesian Ensemble Deep Learning*. Mereka menambahkan konsep *uncertainty-aware* agar sistem tidak hanya memberikan prediksi nilai tekanan darah, tetapi juga memperkirakan tingkat ketidakpastian prediksi tersebut. Inovasi ini sangat penting untuk aplikasi medis, karena memberikan indikator kepercayaan terhadap hasil estimasi. Meski demikian, penelitian ini memerlukan sumber daya komputasi yang sangat besar sehingga sulit diimplementasikan pada perangkat dengan spesifikasi terbatas.

Dari berbagai penelitian terdahulu tersebut, dapat dilihat bahwa pendekatan estimasi tekanan darah non-invasif telah mengalami perkembangan

signifikan, baik dari sisi metode pemrosesan sinyal maupun pemodelan machine learning. Namun, terdapat beberapa *research gap* yang dapat diidentifikasi. Pertama, sebagian besar studi menggunakan model deep learning yang kompleks dan membutuhkan dataset besar, sehingga sulit diterapkan dalam kondisi nyata dengan keterbatasan data. Kedua, penelitian yang menggunakan MLP sebagai model sederhana masih sangat terbatas, padahal MLP memiliki potensi besar dalam memproses fitur statistik dari sinyal rPPG dengan beban komputasi rendah. Ketiga, sebagian besar penelitian masih sebatas pada tahap eksperimen laboratorium dan belum banyak yang mengembangkan sistem *end-to-end* dengan antarmuka pengguna yang aplikatif.

Berdasarkan penelitian-penelitian tersebut, dapat dilihat bahwa sebagian besar studi menggunakan dataset besar, perangkat rekaman beresolusi tinggi, dan kondisi lingkungan terkontrol. Penelitian ini berbeda karena memanfaatkan kamera standar (smartphone/webcam), dataset terbatas (109 video), dan integrasi sistem ke dalam aplikasi berbasis Streamlit dengan database penyimpanan hasil. Kebaruan penelitian ini terletak pada aspek *end-to-end system* yang ramah pengguna, meskipun nilai *error* masih relatif lebih tinggi dibanding penelitian internasional.

B. Landasan Teori

Pada bagian ini terdiri dari teori-teori pendukung untuk penelitian ini, yang bertujuan untuk memberikan arahan, justifikasi dan kerangka kerja dari penelitian yang akan dilaksanakan.

1. Tekanan Darah Dan Pengukuran

Tekanan darah adalah tekanan yang dihasilkan darah terhadap

dinding arteri selama siklus jantung. Dua parameter utama tekanan darah, yaitu:

- **Sistolik**: Tekanan maksimum saat jantung berkontraksi memompa darah ke arteri.
- **Diastolik**: Tekanan minimum saat jantung relaksasi di antara detak.

Pengukuran dilakukan dengan alat tensimeter, baik manual (aneroid) maupun digital. Alat tersebut bekerja secara kontak langsung ke lengan pengguna, yang memiliki keterbatasan seperti membutuhkan keahlian medis, kurang nyaman untuk pengukuran rutin, serta potensi kesalahan manusiawi. Oleh karena itu, riset teknologi pengukuran tekanan darah non-invasif menjadi penting untuk memudahkan masyarakat melakukan pengecekan mandiri (Zuhdi et al., 2020).

2. Metode Konvensional (*Cuff-Based*)

Metode standar pengukuran tekanan darah adalah menggunakan *sphygmomanometer* dengan manset yang dipasang di lengan. Alat ini bisa berbasis merkuri, aneroid, maupun digital. Kelebihannya adalah akurasi tinggi, namun metode ini hanya dapat digunakan pada satu waktu pengukuran, tidak nyaman untuk pemantauan kontinu, dan membutuhkan alat khusus (Kachuee et al., 2017).

3. Estimasi Tekanan Darah *Cuffless*

Pengukuran *cuffless* bertujuan memperkirakan tekanan darah tanpa manset. Salah satu metode populer adalah *photoplethysmography* (PPG), yang menggunakan sensor optik untuk mendeteksi perubahan

volume darah pada kulit. Metode ini dapat diintegrasikan ke perangkat *wearable* seperti smartwatch. Perkembangan lebih lanjut adalah *remote photoplethysmography* (rPPG), yang tidak membutuhkan sensor kontak, melainkan memanfaatkan kamera biasa untuk merekam wajah dan mengekstraksi sinyal fisiologis (Verkruysse et al., 2008).

4. *Remote Photoplethysmography* (rPPG)

Remote Photoplethysmography (rPPG) adalah metode pengukuran sinyal fisiologis yang menggunakan kamera untuk mendeteksi perubahan warna kulit wajah akibat fluktuasi aliran darah pada kapiler. Konsep ini berasal dari teknologi PPG (*Photoplethysmography*) kontak, yang umumnya dipasang di ujung jari, namun rPPG tidak memerlukan sensor tambahan sehingga lebih praktis dan non-invasif (Verkruysse et al., 2008).


Menurut (Hwang & Lee, 2024), rPPG dapat digunakan untuk memperkirakan tekanan darah dengan mengolah sinyal cahaya yang dipantulkan wajah dan memperhitungkan pergeseran fase (*phase shift*). Keunggulan rPPG adalah kemudahan implementasi menggunakan kamera smartphone atau laptop, namun tantangannya meliputi kualitas pencahayaan, pergerakan wajah, dan variasi warna kulit.

rPPG memanfaatkan fluktuasi intensitas cahaya pada kulit wajah yang ditangkap kamera. Kanal warna hijau umumnya digunakan karena memberikan sensitivitas terbaik terhadap perubahan aliran darah (Poh et al., 2010). Sinyal rPPG perlu melewati proses *preprocessing* seperti *detrending*, *band-pass filtering*, *normalization* untuk mengurangi noise

akibat pencahayaan dan gerakan.

Prinsip rPPG:

- Kamera menangkap perubahan warna wajah yang dipicu denyut darah.
- Ekstraksi sinyal RGB dari Region of Interest (ROI), biasanya dahi atau pipi.
- Preprocessing dan filtering sinyal untuk menghilangkan noise.
- Algoritma mengolah sinyal menjadi fitur fisiologis.



Gambar 2.1 Ilustrasi prinsip rPPG wajah

Sumber: (Verkruysse et al., 2008)

5. Analisis Wajah untuk Deteksi Tekanan Darah

Deep learning adalah pendekatan machine learning mutakhir yang sangat efektif untuk ekstraksi fitur kompleks dari data visual. Dalam konteks fisiologi, deep learning, terutama *Convolutional Neural Networks (CNN)*, dilatih untuk mengenali pola-pola biometrik dalam citra wajah yang tidak kasat mata. Jaringan CNN dapat mendeteksi dan mengekstraksi fitur-fitur penting seperti tekstur, warna, hingga

perubahan mikro yang merepresentasikan sinyal fisiologis akibat variasi tekanan darah (X. Liu et al., 2023)

Pipeline umumnya:

- **Face Detection:** Mendeteksi dan menandai posisi wajah pada video secara real-time.
- **ROI Extraction:** Memilih area strategis di wajah, misal dahi, untuk ekstraksi sinyal.
- **Signal Extraction:** Mengambil sinyal rPPG berbasis perubahan warna RGB.
- **Deep Feature Learning:** CNN digunakan untuk mengekstraksi/memodelkan hubungan fitur wajah dengan tekanan darah sistolik–diastolik.
- **Regresi/Predictor:** Model meregresikan nilai tekanan darah berdasarkan fitur deep learning.

6. Ekstraksi Fitur dari Sinyal rPPG

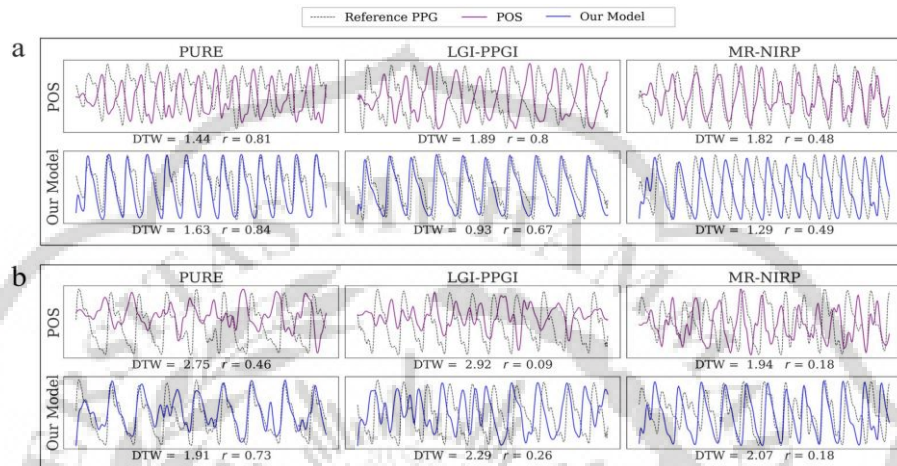
Sinyal rPPG mentah masih banyak mengandung *noise* dari pencahayaan maupun gerakan wajah. Oleh karena itu, perlu dilakukan pra-pemrosesan dengan *band-pass filter* (biasanya 0,7–4 Hz) agar sinyal lebih stabil (Qiao et al., 2022).

Fitur yang digunakan dalam penelitian ini meliputi:

- Statistik dasar: rata-rata, standar deviasi, varians, skewness, kurtosis.
- Fitur spektral: energi spektral, frekuensi dominan.

- Parameter fisiologis: puncak dan interval sinyal.

Menurut (Schrumpf et al., 2021), pemilihan fitur yang tepat sangat memengaruhi kualitas prediksi tekanan darah.

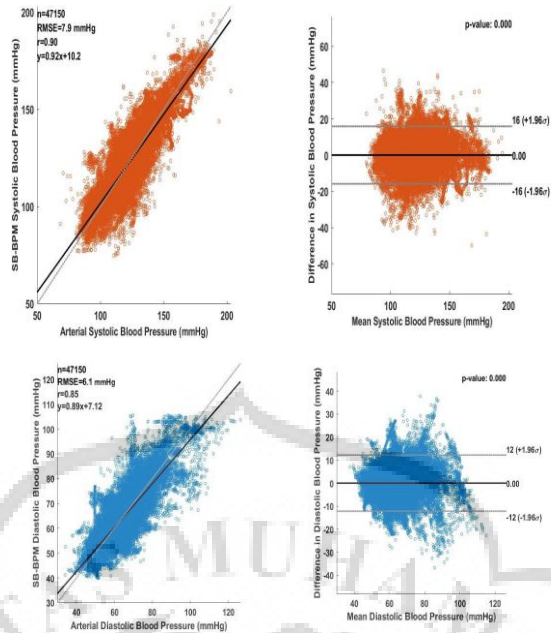


Gambar 2.2 Contoh sinyal rPPG mentah dan hasil filtering
Sumber: (Castellano Ontiveros et al., 2024)

7. *Linear Regression* sebagai Model *Baseline*

Linear Regression digunakan sebagai model *baseline* untuk melihat hubungan linier antara fitur rPPG dengan tekanan darah. Model ini sederhana, cepat dilatih, dan dapat memberikan gambaran awal apakah sinyal rPPG memiliki keterkaitan dengan tekanan darah.

Penelitian oleh (Chen et al., 2023) menunjukkan bahwa regresi linear dapat digunakan untuk estimasi tekanan darah berbasis sinyal PPG, namun hasilnya terbatas pada kondisi tertentu. Oleh karena itu, regresi linear lebih tepat dipakai sebagai pembanding (*baseline*), bukan model utama.



Gambar 2.3 Diagram regresi linear
Sumber: (Haddad et al., 2022)

8. Multi-Layer Perceptron (MLP) dalam Deep Learning

Multi-Layer Perceptron (MLP) adalah jenis jaringan saraf tiruan dengan beberapa lapisan tersembunyi yang mampu mempelajari hubungan *non-linier* antara *input* dan *output*. Setiap neuron melakukan transformasi linier diikuti fungsi aktivasi (ReLU, sigmoid, dsb.) sehingga memungkinkan pemodelan yang lebih kompleks dibanding *regresi linear* (Goodfellow et al., 2016).

Dalam penelitian ini, MLP dipilih untuk memprediksi tekanan darah karena dataset relatif kecil dan berupa data tabular (fitur statistik). (Qiao et al., 2022) membuktikan bahwa MLP mampu memberikan hasil lebih baik dibanding *regresi linear* pada estimasi tekanan darah berbasis video wajah.

Multi-Layer Perceptron (MLP) merupakan salah satu arsitektur dasar dalam jaringan saraf tiruan (*artificial neural network*). MLP

termasuk jaringan saraf *feedforward* yang terdiri dari tiga komponen utama, yaitu:

- **Lapisan input (*input layer*)**, yang menerima data masukan berupa vektor fitur. Dalam konteks penelitian ini, masukan berasal dari 12 fitur statistik dan spektral yang diekstraksi dari sinyal rPPG.
- **Lapisan tersembunyi (*hidden layer*)**, yang berfungsi mempelajari representasi non-linear dari data. Setiap lapisan tersembunyi memiliki sejumlah neuron yang saling terhubung dengan bobot (*weights*) dan bias tertentu. Bobot inilah yang dilatih pada saat proses *training*.
- **Lapisan output (*output layer*)**, yang menghasilkan keluaran berupa prediksi nilai numerik. Pada penelitian ini, lapisan output terdiri atas dua neuron yang masing-masing merepresentasikan prediksi tekanan darah sistolik (SBP) dan diastolik (DBP).

Arsitektur MLP pada penelitian ini dapat digambarkan sebagai berikut:

- **Lapisan input:** 12 node (fitur rPPG).
- **Hidden layer pertama:** 64 neuron dengan fungsi aktivasi ReLU.
- **Hidden layer kedua:** 32 neuron dengan fungsi aktivasi ReLU.
- **Lapisan output:** 2 neuron (SBP dan DBP) dengan fungsi

aktivasi linear (karena tugas ini bersifat regresi).

9. Fungsi Aktivasi: ReLU

Fungsi aktivasi berperan penting dalam jaringan saraf karena memperkenalkan *non-linearity*, sehingga model dapat mempelajari hubungan kompleks antara fitur masukan dan keluaran. Pada penelitian ini digunakan *Rectified Linear Unit* (ReLU), yang secara matematis didefinisikan sebagai:

$$f(x) = \max(0, x)$$

Artinya, semua nilai input negatif akan diubah menjadi nol, sedangkan nilai positif dipertahankan. Keunggulan utama ReLU adalah:

- Mengurangi masalah *vanishing gradient* yang sering terjadi pada fungsi aktivasi sigmoid atau tanh.
- Lebih sederhana secara komputasi karena hanya membutuhkan operasi ambang batas (thresholding).
- Mempercepat proses pelatihan karena menghasilkan sparsity (banyak neuron dengan keluaran nol).

10. Kelebihan MLP untuk Tugas Regresi Tekanan Darah

Penggunaan MLP dalam penelitian ini didasarkan pada beberapa pertimbangan sebagai berikut:

1) Kemampuan memodelkan hubungan non-linear

Hubungan antara fitur statistik rPPG dengan tekanan darah tidak selalu linear. Model regresi sederhana (linear regression) cenderung gagal

menangkap pola kompleks ini. MLP dengan beberapa hidden layer mampu membentuk fungsi non-linear yang lebih representatif sehingga meningkatkan akurasi prediksi.

2) Kompleksitas rendah namun efektif


Berbeda dengan CNN atau LSTM yang memerlukan dataset besar dan komputasi tinggi, MLP relatif sederhana dan ringan untuk dijalankan pada perangkat standar seperti laptop atau smartphone. Hal ini sesuai dengan tujuan penelitian yang ingin menghasilkan sistem yang dapat diimplementasikan secara praktis.

3) Fleksibilitas input

MLP dapat menerima masukan berupa vektor fitur yang sudah diekstraksi dari sinyal, sehingga sangat cocok digunakan setelah tahap preprocessing rPPG. Dengan demikian, model ini tidak membutuhkan data citra mentah yang berukuran besar.

4) Kesesuaian untuk tugas regresi

MLP dapat digunakan tidak hanya untuk klasifikasi, tetapi juga untuk regresi dengan menyesuaikan fungsi aktivasi di lapisan output menjadi linear. Hal ini membuat MLP ideal untuk memprediksi nilai kontinu seperti tekanan darah sistolik dan diastolik.



Gambar 2.4 Arsitektur sederhana MLP untuk prediksi tekanan darah

Sumber: (Sagala, 2023)

