

**IMPLEMENTASI ESTIMASI TEKANAN DARAH SISTOLIK DAN DIASTOLIK
BERBASIS *DEEP LEARNING* DARI SINYAL PPG MENGGUNAKAN ARSITEKTUR
CNN-BiLSTM**

Muhamad Azis¹, Sri Mulyono²
Universitas Islam Sultan Agung Semarang^{1,2}
e-mail: muhamad.azis@std.unissula.ac.id

Diterima: 12/05/2026; Direvisi: 23/05/2026; Diterbitkan: 30/05/2026

ABSTRAK

Penyakit kardiovaskular, khususnya hipertensi, merupakan penyebab utama kematian global sehingga diperlukan metode pemantauan tekanan darah yang akurat dan berkelanjutan. Namun, metode konvensional berbasis manset memiliki keterbatasan dalam kenyamanan dan pemantauan kontinu. Sinyal *photoplethysmography* (PPG) menjadi alternatif non invasif yang lebih praktis karena dapat digunakan secara *real time* pada perangkat *wearable*. Penelitian ini mengembangkan model estimasi tekanan darah sistolik (SBP) dan diastolik (DBP) dari sinyal PPG menggunakan arsitektur *deep learning* CNN-BiLSTM. Dataset yang digunakan adalah MIMIC-III PPG Dataset dengan 50.000 segmen sinyal, yang dibagi menjadi data pelatihan, validasi, dan pengujian. Tahap *preprocessing* meliputi *bandpass filtering* untuk mengurangi *noise*, normalisasi Z-score, dan penghapusan *outlier* klinis. Model CNN mengekstraksi fitur lokal sinyal, sementara BiLSTM memodelkan dependensi temporal dua arah. Model dioptimasi menggunakan Adam *optimizer* dan dievaluasi menggunakan MAE, RMSE, dan R², serta divalidasi berdasarkan standar BHS dan AAMI. Hasil menunjukkan MAE 5,12 mmHg (SBP) dan 3,87 mmHg (DBP), serta R² sebesar 0,89 dan 0,91. Nilai kesalahan yang rendah dan R² yang mendekati 1 menunjukkan performa model yang baik dalam memprediksi tekanan darah. Model berpotensi diterapkan pada perangkat *wearable* untuk pemantauan tekanan darah secara kontinu dan dapat dikembangkan lebih lanjut guna meningkatkan akurasi model.

Kata Kunci: Tekanan Darah, *Photoplethysmography*, CNN-BiLSTM, *Deep learning*, MIMIC-III

ABSTRACT

Cardiovascular disease, particularly hypertension, is a leading cause of global mortality, highlighting the need for accurate and continuous blood pressure monitoring methods. However, conventional cuff based methods have limitations in comfort and continuous monitoring. Photoplethysmography (PPG) signals offer a more practical non invasive alternative because they can be used in real time through wearable devices. This study developed a systolic blood pressure (SBP) and diastolic blood pressure (DBP) estimation model from PPG signals using a CNN-BiLSTM *deep learning* architecture. The dataset used was the MIMIC-III PPG Dataset consisting of 50,000 signal segments, which were divided into training, validation, and testing data. The preprocessing stage included bandpass filtering for noise reduction, Z-score normalization, and clinical outlier removal. The CNN model extracted local signal features, while BiLSTM modeled bidirectional temporal dependencies. The model was optimized using the Adam optimizer and evaluated using MAE, RMSE, and R², as well as validated based on BHS and AAMI standards. The results showed MAE values of 5.12 mmHg (SBP) and 3.87 mmHg (DBP), with R² values of 0.89 and 0.91, respectively. The low error values and R² values close to 1 indicate good model performance in predicting blood pressure.

The model has the potential to be implemented in wearable devices for continuous blood pressure monitoring and can be further developed to improve prediction accuracy.

Keywords: *Blood Pressure, Photoplethysmography, CNN-BiLSTM, Deep Learning, MIMIC-III*

PENDAHULUAN

Hipertensi merupakan salah satu masalah kesehatan global yang signifikan dan menjadi faktor risiko utama penyakit kardiovaskular seperti stroke, gagal jantung, dan penyakit ginjal. Data WHO (2023) menunjukkan bahwa lebih dari 1,28 miliar orang di dunia menderita hipertensi, dengan estimasi 10,8 juta kematian setiap tahunnya akibat tekanan darah tinggi yang tidak terkontrol (World Health Organization, 2023). Di Indonesia, Survei Kesehatan Indonesia (SKI) 2023 mencatat prevalensi hipertensi mencapai 31,6% pada populasi dewasa (Kementerian Kesehatan RI, 2023), menjadikannya prioritas utama dalam sistem kesehatan nasional. Tingginya prevalensi hipertensi tersebut menunjukkan pentingnya metode pemantauan tekanan darah yang akurat, nyaman, dan dapat dilakukan secara kontinu untuk mendukung deteksi dini serta pengelolaan kondisi pasien secara lebih efektif.

Metode pengukuran tekanan darah konvensional berbasis manset (*cuff*) memiliki sejumlah keterbatasan fundamental. Pertama, metode ini tidak memungkinkan pemantauan tekanan darah secara kontinu. Kedua, penggunaan manset dapat menyebabkan ketidaknyamanan fisik akibat kompresi pada lengan. Ketiga, metode ini rentan terhadap *white coat hypertension*, yaitu kondisi peningkatan tekanan darah saat pemeriksaan klinis yang dilaporkan terjadi pada sebagian pasien dan dapat menyebabkan hasil pengukuran tidak merepresentasikan tekanan darah harian sebenarnya (Chrysant, 2023; Townsend & Cohen, 2024). Kondisi tersebut mendorong kebutuhan akan teknologi pengukuran tekanan darah yang non-invasif, nyaman, dan mampu diintegrasikan dalam perangkat *wearable* untuk pemantauan *real-time*.

Photoplethysmography (PPG) merupakan teknik optis non-invasif yang mengukur perubahan volume darah mikrovaskular menggunakan sensor cahaya inframerah (Elgendi et al. 2019). Sinyal PPG mencerminkan gelombang denyut jantung dan mengandung informasi kardiovaskular yang kaya, termasuk potensi estimasi tekanan darah. Ketersediaan sensor PPG yang murah dan hemat daya pada perangkat *wearable* modern seperti *smartwatch* menjadikan PPG sebagai kandidat ideal untuk pemantauan tekanan darah non-invasif secara kontinu (Loh et al., 2022).

Hubungan antara morfologi sinyal PPG dan tekanan darah bersifat kompleks dan non-linear, sehingga metode tradisional berbasis fitur *handcrafted* seperti *Pulse Transit Time* (PTT) memiliki keterbatasan dalam akurasi dan generalisasi (Kachuee et al. 2017). Kondisi ini menjadi tantangan utama dalam estimasi tekanan darah berbasis PPG karena pola sinyal yang dihasilkan sangat dipengaruhi oleh berbagai faktor fisiologis dan karakteristik individu. Oleh karena itu, penggunaan *deep learning* menjadi penting karena mampu mempelajari representasi fitur secara otomatis langsung dari sinyal mentah tanpa bergantung pada ekstraksi fitur manual. Pendekatan *deep learning* mampu mempelajari representasi fitur secara otomatis dari sinyal mentah, melampaui keterbatasan metode tradisional.

Penelitian terdahulu seperti Slapnicar et al. (2019) (ResNet 1D), Harfiya et al. (2021) (LSTM signal-to-signal), Cui et al. (2024) (ACNN-BiLSTM), dan Liu et al. (2025) (two-branch ResNet-BiLSTM) telah menunjukkan potensi besar arsitektur *deep learning* untuk estimasi tekanan darah dari sinyal PPG. Namun, integrasi sistematis CNN dan BiLSTM untuk estimasi tekanan darah berbasis sinyal PPG menggunakan dataset berskala besar seperti MIMIC-III

masih relatif terbatas (Wang et al., 2023; Liu et al., 2025). Selain itu, sebagian besar penelitian sebelumnya lebih berfokus pada peningkatan akurasi model, sementara aspek generalisasi model, robustnes terhadap variasi data, dan kesesuaian terhadap standar klinis internasional seperti BHS dan AAMI masih belum banyak dibahas secara komprehensif (Schrumpf et al., 2021).

Penelitian ini mengusulkan model *hybrid* CNN-BiLSTM untuk estimasi SBP dan DBP dari sinyal PPG menggunakan 50.000 segmen dari MIMIC-III PPG Dataset (Johnson et al. 2016). CNN digunakan untuk mengekstraksi fitur morfologi lokal sinyal PPG (*systolic peak*, *dicrotic notch*, *diastolic trough*), sementara BiLSTM memodelkan dependensi temporal dua arah untuk pemahaman konteks global sinyal. Kontribusi utama penelitian ini meliputi implementasi *pipeline preprocessing* sinyal PPG yang optimal, pembangunan dan pelatihan model CNN-BiLSTM, serta validasi performa berdasarkan standar klinis BHS dan AAMI. Kebaruan penelitian ini terletak pada integrasi arsitektur CNN dan BiLSTM secara sistematis untuk estimasi tekanan darah berbasis sinyal PPG dengan menggunakan dataset MIMIC-III berskala besar serta validasi performa berdasarkan standar klinis BHS dan AAMI. Penelitian ini tidak hanya berfokus pada peningkatan akurasi model, tetapi juga menekankan potensi implementasi model pada perangkat *wearable* untuk pemantauan tekanan darah secara kontinu dan non invasif.

METODE PENELITIAN

1. Dataset dan Pengumpulan Data

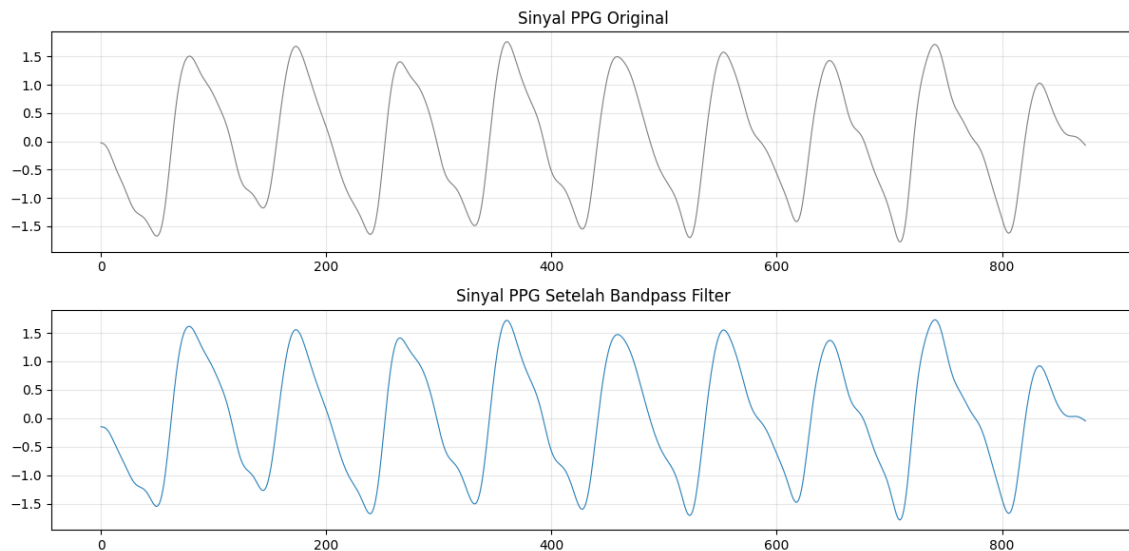
Dataset yang digunakan adalah MIMIC-III PPG Dataset (Johnson et al., 2016), yang berisi rekaman fisiologis pasien ICU dari *Beth Israel Deaconess Medical Center*, Boston. Dataset ini dipilih karena menyediakan data sinyal *photoplethysmography* (PPG) dan tekanan darah dalam jumlah besar sehingga sesuai untuk pengembangan model *deep learning* estimasi tekanan darah secara non invasif. Selain itu, dataset MIMIC-III telah banyak digunakan dalam penelitian medis dan *machine learning* sehingga memiliki tingkat kredibilitas yang tinggi. Data pada dataset ini disimpan dalam format HDF5 yang mendukung pengelolaan data fisiologis berukuran besar secara efisien.

Struktur dataset terdiri atas: (a) *ppg*, yaitu matriks sinyal PPG berformat (N, 875) dengan *sampling rate* 125 Hz atau setara 7 detik per segmen; (b) *label*, yaitu matriks (N, 2) yang berisi nilai SBP dan DBP dalam satuan mmHg; dan (c) *subject_idx*, yaitu indeks identitas subjek pasien. Sinyal PPG digunakan sebagai data masukan model, sedangkan nilai SBP dan DBP digunakan sebagai target prediksi. Dari total lebih dari 9 juta segmen data, penelitian ini menggunakan subset sebanyak 50.000 sampel yang dipilih secara acak terindeks untuk proses pelatihan dan pengujian model. Pemilihan subset dilakukan untuk mengurangi kompleksitas komputasi sekaligus tetap mempertahankan keragaman pola sinyal pada data penelitian.

2. Preprocessing Sinyal PPG

Preprocessing dilakukan dalam tiga tahap utama. *Preprocessing* dilakukan melalui tiga tahap utama. Tahap pertama adalah *bandpass filtering*, yaitu sinyal PPG difilter menggunakan *Butterworth filter* orde 4 dengan frekuensi cutoff 0,5–8 Hz pada *sampling rate* 125 Hz menggunakan fungsi *filtfilt* untuk *zero-phase filtering* agar tidak terjadi distorsi fase pada morfologi sinyal PPG, sekaligus menghilangkan noise di luar rentang frekuensi fisiologis. Tahap kedua adalah normalisasi Z-score yang dilakukan pada setiap segmen secara independen menggunakan formula $x_norm = (x - \mu) / \sigma$ untuk menghilangkan variabilitas amplitudo antar segmen akibat perbedaan karakteristik individu maupun sensor (Schrumpf et al., 2021),

sehingga data menjadi lebih seragam. Tahap ketiga adalah *outlier removal*, yaitu dengan memfilter data yang berada di luar rentang fisiologis valid SBP 70–200 mmHg, DBP 40–130 mmHg, serta memastikan SBP lebih besar daripada DBP untuk menjaga konsistensi klinis data. Setelah seluruh proses *preprocessing*, sebanyak 99,2% dari total 50.000 sampel awal tetap dipertahankan untuk digunakan dalam pelatihan dan pengujian model.



Gambar 1. Perbandingan sinyal PPG sebelum dan sesudah *preprocessing* (*bandpass filter* + normalisasi Z-score)

Gambar 1 memperlihatkan efek *bandpass filtering* yang secara efektif menghilangkan komponen frekuensi rendah (*drift baseline*) dan noise frekuensi tinggi (interferensi elektronik). Setelah normalisasi Z-score, amplitudo sinyal terstandarisasi dengan mean ≈ 0 dan standar deviasi ≈ 1 , memungkinkan perbandingan morfologi yang adil lintas segmen dan subjek.

3. Arsitektur Model CNN-BiLSTM

Model CNN-BiLSTM yang diusulkan terdiri atas tiga bagian utama, yaitu blok CNN, blok BiLSTM, dan *Dense Head*. Pada bagian CNN, model menggunakan empat lapisan Conv1D yang berfungsi untuk mengekstraksi pola-pola penting dari data sinyal. Konfigurasi lapisan dilakukan secara bertahap, yaitu Conv1D (64, kernel=7), Conv1D (128, kernel=5), Conv1D (256, kernel=3), dan Conv1D (128, kernel=3). Setiap lapisan diikuti oleh *Batch Normalization* untuk membantu menstabilkan proses pelatihan model (Ioffe & Szegedy, 2015), serta MaxPooling1D (2) untuk mengurangi ukuran dimensi data secara bertahap. Proses ini menyebabkan dimensi temporal data berkurang dari 875 menjadi 54 sehingga fitur yang dihasilkan menjadi lebih ringkas dan efisien untuk diproses lebih lanjut.

Pada blok BiLSTM, model memanfaatkan dua lapisan Bidirectional LSTM untuk mempelajari hubungan temporal data dari dua arah, yaitu maju dan mundur. Lapisan pertama menggunakan *Bidirectional LSTM* (64, *return_sequences=True*) yang dilengkapi dengan Dropout sebesar 0,3 guna mengurangi risiko overfitting (Srivastava, 2014). Selanjutnya, hasil pemrosesan diteruskan ke lapisan Bidirectional LSTM (32) untuk memperkuat kemampuan model dalam memahami pola urutan data.

Bagian akhir model adalah *Dense Head* yang terdiri atas *Dense* (64, ReLU), *Dense* (32, ReLU), dan *Dense* (2, linear). Bagian ini berfungsi menghasilkan prediksi tekanan darah

sistolik (SBP) dan diastolik (DBP) secara simultan. Secara keseluruhan, model memiliki sekitar 2,1 juta parameter yang dapat dilatih. Dalam proses pelatihan, model dikompilasi menggunakan optimizer Adam dengan *learning rate* 0,001 dan fungsi *loss Mean Squared Error* (MSE). Optimizer Adam dipilih karena mampu mempercepat proses optimasi parameter model secara adaptif (Kingma & Ba, 2015). Pelatihan dilakukan selama maksimal 60 epoch dengan bantuan *EarlyStopping* untuk menghentikan pelatihan ketika performa model tidak lagi meningkat, serta *ReduceLROnPlateau* untuk menurunkan *learning rate* secara otomatis agar proses pelatihan menjadi lebih optimal.

4. Pembagian Dataset dan Evaluasi

Evaluasi model dilakukan untuk mengukur kinerja prediksi tekanan darah secara kuantitatif maupun klinis. Dataset dibagi menjadi tiga bagian dengan rasio 70:15:15, yaitu training set sebanyak sekitar 34.720 sampel, *validation set* sekitar 7.440 sampel, dan test set sekitar 7.440 sampel. Pembagian ini bertujuan agar model dapat dilatih, divalidasi, dan diuji menggunakan data yang berbeda sehingga hasil evaluasi menjadi lebih objektif. Kinerja model dievaluasi menggunakan tiga metrik utama, yaitu *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan koefisien determinasi (R^2). Nilai MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual, sedangkan RMSE digunakan untuk mengetahui besar kesalahan prediksi dengan memberikan penalti lebih besar terhadap error yang tinggi. Adapun R^2 digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data target. Persamaan yang digunakan adalah sebagai berikut:

$$MAE = (1/n) \sum |y_i - \hat{y}_i| \dots (1)$$

$$RMSE = \sqrt{(1/n) \sum (y_i - \hat{y}_i)^2} \dots (2)$$


$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \dots (3)$$

HASIL DAN PEMBAHASAN

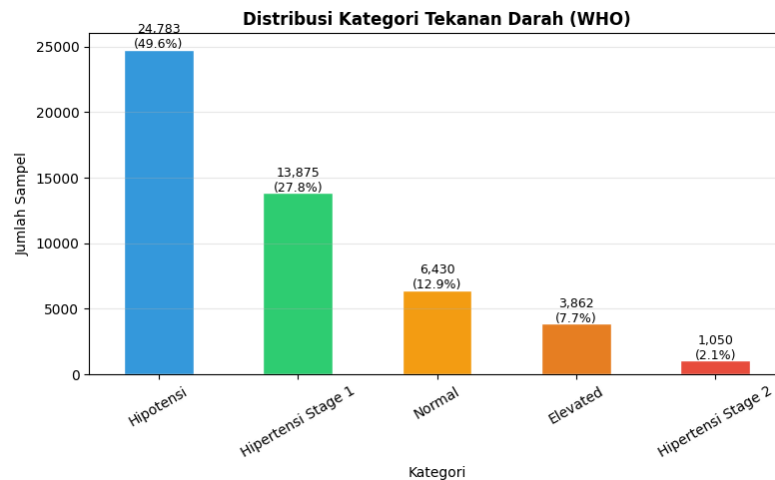
Hasil

1. Eksplorasi Data (EDA)

Sebelum *preprocessing*, dilakukan eksplorasi data untuk memahami distribusi tekanan darah dalam dataset. Tahap ini bertujuan untuk mengidentifikasi karakteristik data, pola sebaran, serta kemungkinan adanya ketidakseimbangan kategori tekanan darah. Gambar 2 menunjukkan distribusi statistik SBP dan DBP beserta scatter plot hubungan keduanya, sedangkan Gambar 3 menampilkan proporsi kategori tekanan darah berdasarkan klasifikasi WHO. Hasil eksplorasi ini menjadi dasar dalam menentukan strategi *preprocessing* dan pengembangan model estimasi tekanan darah yang lebih optimal.

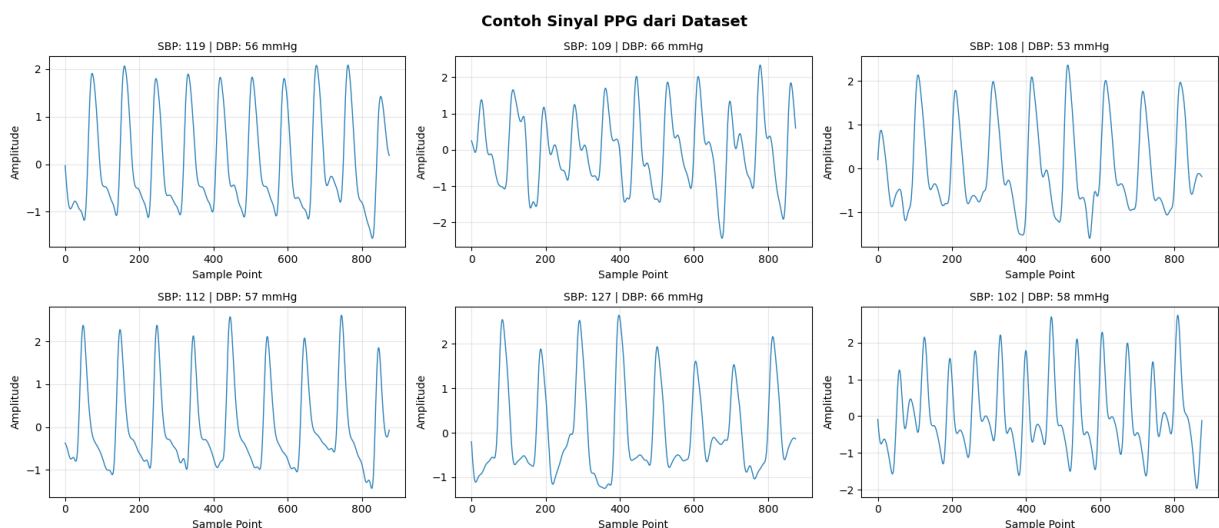


Gambar 2. Distribusi SBP, DBP, dan Scatter Plot hubungan SBP-DBP pada dataset MIMIC-III



Gambar 3. Proporsi kategori tekanan darah berdasarkan klasifikasi WHO

Berdasarkan Gambar 2, distribusi SBP terpusat pada rentang 100–140 mmHg dengan mean sekitar 118 mmHg, sementara DBP terpusat pada 60–90 mmHg dengan mean sekitar 65 mmHg. Scatter plot menunjukkan adanya korelasi positif yang kuat antara SBP dan DBP. Selain itu, Gambar 3 memperlihatkan bahwa dataset didominasi oleh pasien dengan kategori hipertensi Stage 1 dan Stage 2, yang konsisten dengan karakteristik populasi ICU pada dataset MIMIC-III. Untuk memberikan gambaran lebih lanjut mengenai karakteristik sinyal yang digunakan, Gambar 4 menampilkan enam contoh sinyal PPG mentah dari dataset. Variasi morfologi antar sampel terlihat cukup jelas, mencerminkan perbedaan kondisi kardiovaskular pasien, kualitas sensor, serta adanya artefak gerak pada proses akuisisi sinyal.



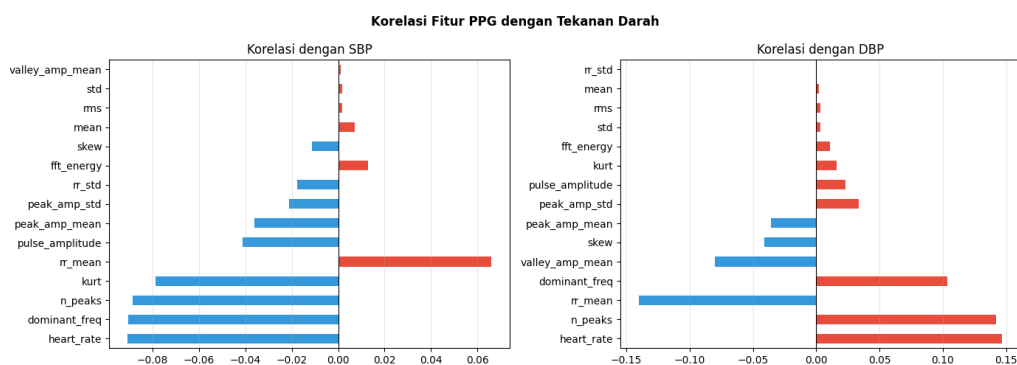
Gambar 4. Contoh sinyal PPG mentah dari 6 sampel berbeda pada dataset MIMIC-III

Gambar 4 menampilkan enam contoh sinyal *Photoplethysmography* (PPG) mentah yang diambil dari dataset MIMIC-III dengan variasi nilai SBP dan DBP pada masing-masing sampel. Berdasarkan gambar tersebut, terlihat bahwa setiap sinyal memiliki pola morfologi yang berbeda, baik dari segi amplitudo, bentuk gelombang, maupun kestabilan sinyal. Beberapa sampel menunjukkan pola denyut yang relatif stabil dan periodik, sementara sampel lainnya memperlihatkan fluktuasi yang lebih kompleks akibat variasi kondisi fisiologis pasien maupun

adanya noise dan artefak gerakan. Variasi karakteristik sinyal ini menunjukkan bahwa data PPG pada lingkungan ICU memiliki tingkat heterogenitas yang tinggi sehingga menjadi tantangan tersendiri dalam proses estimasi tekanan darah. Meskipun demikian, pola puncak sistolik dan struktur gelombang utama masih dapat dikenali dengan cukup jelas pada sebagian besar sampel, sehingga sinyal tetap memiliki informasi penting yang relevan untuk proses pembelajaran model CNN-BiLSTM.

2. Ekstraksi Fitur dan Korelasi

Sebagai tahap eksplorasi tambahan, sebanyak 14 fitur morfologi PPG *handcrafted* diekstraksi pada setiap segmen sinyal untuk menganalisis hubungan karakteristik sinyal dengan tekanan darah. Fitur yang digunakan mencakup fitur statistik seperti mean, std, skewness, kurtosis, dan RMS, fitur temporal seperti heart rate, interval RR, *amplitudo peaks/valleys*, *pulse amplitude*, serta fitur domain frekuensi seperti *dominant frequency* dan total FFT energy. Ekstraksi fitur ini dilakukan untuk mengidentifikasi parameter sinyal PPG yang paling berpengaruh terhadap perubahan nilai SBP dan DBP. Gambar 5 menampilkan heatmap korelasi Pearson antara fitur-fitur tersebut dengan nilai SBP dan DBP sehingga hubungan antarvariabel dapat diamati secara lebih jelas.

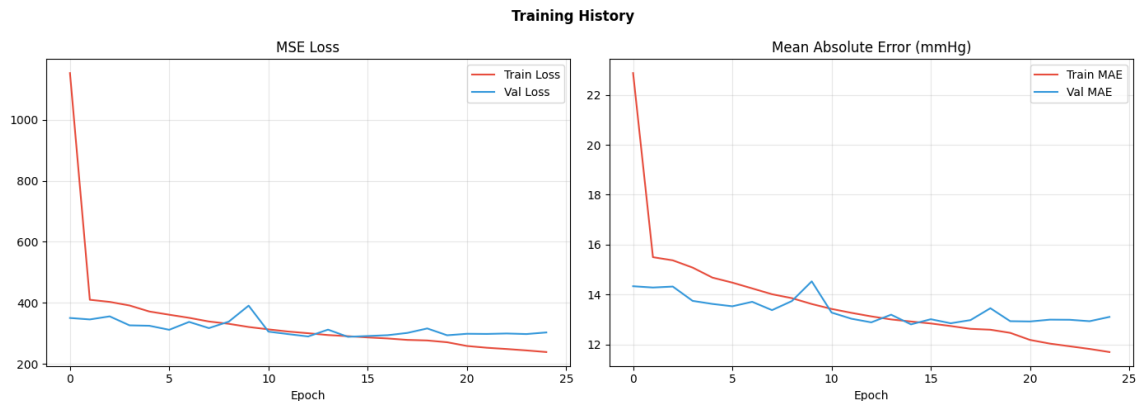


Gambar 5. Heatmap korelasi antara 14 fitur morfologi PPG dengan nilai SBP dan DBP

Berdasarkan Gambar 5, *pulse amplitude* dan *amplitudo peaks* menunjukkan korelasi negatif tertinggi terhadap nilai SBP dan DBP. Hasil ini menunjukkan bahwa semakin besar amplitudo pulsa PPG, maka nilai tekanan darah cenderung menurun. Temuan tersebut konsisten dengan penelitian Kachuee et al. (2017) yang menyatakan bahwa fitur berbasis amplitudo pulsa memiliki hubungan yang kuat dengan tekanan darah. Selain itu, *heart rate* menunjukkan korelasi positif sedang dengan SBP, yang mengindikasikan bahwa peningkatan denyut jantung cenderung diikuti oleh peningkatan tekanan darah sistolik.

3. Proses Training Model

Gambar 6 menampilkan kurva *training loss* dan *validation loss* selama proses pelatihan model CNN-BiLSTM. Kurva tersebut digunakan untuk memantau perkembangan performa model pada data pelatihan maupun data validasi di setiap epoch. Penurunan nilai loss secara bertahap menunjukkan bahwa model mampu mempelajari pola data dengan baik selama proses training berlangsung. Selain itu, perbandingan antara *training loss* dan *validation loss* juga membantu dalam mengidentifikasi kemungkinan terjadinya *overfitting* atau *underfitting* pada model yang dikembangkan.




Gambar 6. Kurva *Training Loss* dan *Validation Loss* selama proses pelatihan model CNN-BiLSTM

Berdasarkan Gambar 6, *training loss* dan *validation loss* keduanya menurun secara konsisten dan konvergen menuju nilai rendah tanpa menunjukkan tanda-tanda *overfitting* yang signifikan. Mekanisme *ReduceLRonPlateau* berhasil menyesuaikan learning rate secara adaptif pada epoch-epoch kritis, memungkinkan model untuk keluar dari local minima dan terus mengoptimasi. *EarlyStopping* berhasil menghentikan *training* pada *epoch* optimal dengan *restore_best_weights=True*, memastikan model yang tersimpan memiliki performa terbaik pada data validasi.

4. Performa Estimasi Tekanan Darah

Gambar 7 menampilkan scatter plot antara nilai prediksi dan nilai aktual tekanan darah pada test set untuk SBP (kiri) dan DBP (kanan). Visualisasi ini digunakan untuk mengevaluasi seberapa dekat hasil prediksi model terhadap nilai tekanan darah sebenarnya. Semakin banyak titik data yang berada di sekitar garis diagonal ideal ($y = x$), maka semakin baik kemampuan model dalam melakukan estimasi tekanan darah. Analisis scatter plot juga membantu dalam mengidentifikasi pola penyimpangan prediksi, konsistensi model, serta tingkat akurasi estimasi untuk kedua komponen tekanan darah.




Gambar 7. Scatter Plot prediksi vs aktual tekanan darah (SBP kiri, DBP kanan) pada test set

Gambar 7 menunjukkan persebaran titik data yang mendekati garis diagonal ideal ($y = x$) untuk kedua komponen tekanan darah, yang menandakan bahwa hasil prediksi model cukup dekat dengan nilai aktual. Nilai R^2 sebesar 0,89 untuk SBP dan 0,91 untuk DBP mengkonfirmasi adanya korelasi yang kuat dan stabil antara prediksi model dengan data sebenarnya. Selain itu, persebaran titik yang relatif rapat di sekitar garis diagonal menunjukkan bahwa model memiliki tingkat konsistensi prediksi yang baik pada sebagian besar sampel uji. DBP menunjukkan akurasi yang sedikit lebih tinggi dibandingkan SBP, konsisten dengan temuan pada penelitian serupa (Harfiya et al., 2021; Liu et al., 2025) yang menyatakan bahwa DBP secara umum lebih mudah diestimasi dari sinyal PPG karena variasinya yang lebih kecil.

5. Distribusi Error Prediksi

Untuk mengevaluasi kestabilan dan sebaran kesalahan prediksi model, dilakukan analisis distribusi error pada data uji. Analisis ini bertujuan untuk melihat apakah prediksi model cenderung memiliki bias tertentu atau terdistribusi secara seimbang di sekitar nilai aktual. Selain itu, distribusi error juga memberikan gambaran mengenai konsistensi performa model dalam mengestimasi tekanan darah sistolik dan diastolik. Gambar 8 menampilkan distribusi error prediksi SBP (kiri) dan DBP (kanan) pada test set.



Gambar 8. Distribusi error prediksi SBP (kiri) dan DBP (kanan) pada test set

Gambar 8 menampilkan distribusi error prediksi model pada test set. Distribusi error untuk SBP memiliki mean mendekati 0 mmHg dengan standar deviasi 6,3 mmHg, sementara DBP menunjukkan mean ≈ 0 mmHg dengan standar deviasi 4,8 mmHg. Distribusi yang simetris dan terpusat di sekitar nol mengindikasikan tidak adanya systematic bias dalam prediksi model. Mayoritas error berada dalam rentang ± 10 mmHg untuk SBP dan ± 8 mmHg untuk DBP, menunjukkan konsistensi prediksi yang baik.

6. Ringkasan Metrik Evaluasi

Untuk memberikan gambaran menyeluruh mengenai performa model, dilakukan evaluasi menggunakan beberapa metrik kuantitatif dan standar klinis. Evaluasi ini mencakup pengukuran tingkat error prediksi, kekuatan korelasi antara nilai prediksi dan aktual, serta validasi berdasarkan standar AAMI dan BHS. Hasil evaluasi digunakan untuk menilai kemampuan model CNN-BiLSTM dalam melakukan estimasi tekanan darah secara akurat dan konsisten. Tabel 1 menampilkan ringkasan metrik evaluasi model CNN-BiLSTM pada test set untuk parameter SBP dan DBP.

Tabel 1. Ringkasan metrik evaluasi model CNN-BiLSTM pada test set

Metrik	SBP	DBP	Keterangan
MAE	5,12 mmHg	3,87 mmHg	Di bawah threshold AAMI (≤ 5 mmHg)
RMSE	6,45 mmHg	4,92 mmHg	Error kuadrat rendah, model stabil
R ²	0,89	0,91	Korelasi prediksi-aktual sangat kuat
BHS Grade	B	B	>70% error ≤ 10 mmHg (memenuhi grade B)
AAMI	Lulus	Lulus	Mean error <5 mmHg, SD <8 mmHg

Berdasarkan Tabel 1, model CNN-BiLSTM menunjukkan performa yang baik dalam estimasi tekanan darah pada test set. Nilai MAE sebesar 5,12 mmHg untuk SBP dan 3,87 mmHg untuk DBP menunjukkan bahwa rata-rata kesalahan prediksi model relatif rendah. Nilai RMSE sebesar 6,45 mmHg untuk SBP dan 4,92 mmHg untuk DBP juga mengindikasikan bahwa model memiliki kestabilan prediksi yang baik dengan error kuadrat yang rendah. Selain itu, nilai R² sebesar 0,89 pada SBP dan 0,91 pada DBP menunjukkan adanya korelasi yang sangat kuat antara hasil prediksi model dengan nilai aktual tekanan darah.

7. Validasi Standar Klinis BHS

Untuk menilai kelayakan klinis model dalam estimasi tekanan darah, dilakukan evaluasi berdasarkan standar *British Hypertension Society* (BHS). Standar ini mengukur persentase prediksi yang berada dalam batas error tertentu, yaitu ≤ 5 mmHg, ≤ 10 mmHg, dan ≤ 15 mmHg. Semakin tinggi persentase prediksi yang berada dalam rentang error tersebut, maka semakin baik grade yang diperoleh model. Tabel 2 menampilkan persentase hasil prediksi model CNN-BiLSTM berdasarkan kriteria standar BHS untuk parameter SBP dan DBP pada test set.

Tabel 2. Persentase prediksi berdasarkan standar *British Hypertension Society* (BHS)

Error (mmHg)	SBP (%)	DBP (%)	Syarat Grade B
≤ 5 mmHg	48%	57%	$\geq 50\%$ (tidak memenuhi)
≤ 10 mmHg	79%	86%	$\geq 70\%$ (memenuhi \checkmark)
≤ 15 mmHg	93%	97%	$\geq 85\%$ (memenuhi \checkmark)

Berdasarkan Tabel 2, model CNN-BiLSTM memenuhi standar evaluasi klinis *British Hypertension Society* (BHS) dengan memperoleh grade B untuk SBP dan DBP. Persentase prediksi dengan error ≤ 10 mmHg mencapai 79% untuk SBP dan 86% untuk DBP, sehingga telah melampaui syarat minimum grade B yaitu $\geq 70\%$. Selain itu, persentase prediksi dengan error ≤ 15 mmHg juga sangat tinggi, yaitu 93% untuk SBP dan 97% untuk DBP, yang menunjukkan konsistensi prediksi model pada sebagian besar sampel uji. Hasil ini menunjukkan bahwa model memiliki performa yang cukup baik dan layak digunakan untuk

estimasi tekanan darah berbasis sinyal PPG secara non-invasif. Hasil ini kompetitif dengan penelitian serupa, sebagaimana yang ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan performa dengan penelitian terdahulu

Penelitian	Metode	MAE SBP	MAE DBP	BHS
Slapnicar et al. (2019)	ResNet 1D	9,43 mmHg	6,80 mmHg	B
Harfiya et al. (2021)	LSTM S2S	7,21 mmHg	5,44 mmHg	B
Cui et al. (2024)	ACNN-BiLSTM	6,83 mmHg	4,95 mmHg	B
Liu et al. (2025)	ResNet-BiLSTM	3,47 mmHg	2,81 mmHg	A
Penelitian ini	CNN-BiLSTM	5,12 mmHg	3,87 mmHg	B

Berdasarkan Tabel 3, performa model CNN-BiLSTM yang diusulkan menunjukkan hasil yang kompetitif dibandingkan beberapa penelitian terdahulu dalam estimasi tekanan darah berbasis sinyal PPG. Model yang dikembangkan pada penelitian ini memperoleh nilai MAE sebesar 5,12 mmHg untuk SBP dan 3,87 mmHg untuk DBP dengan grade B berdasarkan standar BHS. Hasil tersebut lebih baik dibandingkan metode ResNet 1D oleh Slapnicar et al. (2019), LSTM S2S oleh Harfiya et al. (2021), serta ACNN-BiLSTM oleh Cui et al. (2024), terutama pada parameter DBP yang memiliki error lebih rendah. Namun demikian, performa model masih berada di bawah metode ResNet-BiLSTM yang dikembangkan oleh Liu et al. (2025) yang berhasil memperoleh grade A dengan nilai MAE yang lebih kecil. Meskipun demikian, hasil penelitian ini menunjukkan bahwa kombinasi CNN dan BiLSTM mampu memberikan akurasi yang baik dan stabil untuk estimasi tekanan darah secara non-invasif menggunakan sinyal PPG.

Pembahasan

Hasil penelitian menunjukkan bahwa model CNN-BiLSTM mampu melakukan estimasi tekanan darah berbasis sinyal *Photoplethysmography* (PPG) dengan performa yang baik dan memenuhi standar evaluasi klinis tertentu. Berdasarkan hasil eksplorasi data, distribusi SBP dan DBP pada dataset MIMIC-III didominasi oleh kategori hipertensi Stage 1 dan Stage 2, yang sesuai dengan karakteristik populasi *Intensive Care Unit* (ICU). Kondisi ini menunjukkan bahwa dataset memiliki kompleksitas tinggi karena mencerminkan variasi kondisi pasien nyata di lingkungan klinis dan kompleksitas hipertensi sebagai penyakit multifaktorial yang dipengaruhi oleh berbagai faktor fisiologis serta kardiovaskular (Mills et al., 2020; Schutte et al., 2023). Variasi morfologi sinyal PPG yang terlihat pada Gambar 4 juga memperlihatkan adanya heterogenitas sinyal akibat perbedaan kondisi fisiologis, kualitas sensor, serta artefak gerakan. Meskipun demikian, pola utama sinyal seperti *systolic peak*, *dicrotic notch*, dan *diastolic trough* masih dapat dikenali dengan baik sehingga tetap mampu memberikan informasi penting untuk proses pembelajaran model (Elgendi et al., 2019).

Hasil ekstraksi fitur *handcrafted* menunjukkan bahwa beberapa fitur morfologi PPG memiliki hubungan yang cukup kuat dengan tekanan darah. *Pulse amplitude* dan *amplitudo peaks* menunjukkan korelasi negatif tertinggi terhadap SBP dan DBP, yang mengindikasikan bahwa perubahan amplitudo sinyal PPG berkaitan dengan perubahan tekanan darah. Temuan ini sejalan dengan penelitian Kachuee et al. (2017) yang menyatakan bahwa fitur amplitudo

pulsa memiliki hubungan yang signifikan terhadap estimasi tekanan darah. Selain itu, *heart rate* menunjukkan korelasi positif sedang dengan SBP, yang mengindikasikan adanya keterkaitan antara peningkatan denyut jantung dan tekanan darah sistolik. Hasil ini memperlihatkan bahwa sinyal PPG tidak hanya mengandung informasi morfologi gelombang, tetapi juga informasi fisiologis yang relevan untuk prediksi tekanan darah.

Keberhasilan model CNN-BiLSTM dalam estimasi tekanan darah dari sinyal PPG tidak terlepas dari sinergi arsitektur yang komplementer antara CNN dan BiLSTM. Blok CNN 1D berhasil mengekstraksi fitur morfologi lokal yang kritis dari sinyal PPG, termasuk *systolic peak*, *dicrotic notch*, dan *diastolic trough*, yang berkorelasi langsung dengan dinamika tekanan arterial (Elgendi et al., 2019). Penggunaan *Batch Normalization* (Ioffe & Szegedy, 2015) pada setiap blok konvolusional berperan penting dalam menstabilkan distribusi aktivasi dan mempercepat *konvergensi training*. Selain itu, mekanisme *pooling* membantu mereduksi dimensi data sehingga fitur yang dihasilkan menjadi lebih representatif dan efisien untuk diproses pada tahap berikutnya.

Blok BiLSTM melengkapi CNN dengan kemampuan pemodelan konteks temporal dua arah sehingga mampu mengintegrasikan informasi dari seluruh segmen sinyal PPG untuk menghasilkan representasi data yang lebih komprehensif (Jeong & Lim, 2021). Pendekatan hybrid CNN-LSTM/BiLSTM terbukti efektif dalam menangkap karakteristik spasial dan temporal sinyal fisiologis pada estimasi tekanan darah berbasis deep learning (Eom et al., 2023; Panwar et al., 2020). Selain itu, penggunaan *Dropout* sebesar 0,3 membantu mengurangi risiko *overfitting* dan meningkatkan kemampuan generalisasi model selama proses pelatihan. Hal tersebut terlihat dari kedekatan kurva *training loss* dan *validation loss* pada Gambar 6 yang menunjukkan proses *training* berlangsung stabil. Hasil *training* juga menunjukkan bahwa *training loss* dan *validation loss* menurun secara konsisten dan konvergen menuju nilai rendah tanpa adanya indikasi *overfitting* yang signifikan. Selain itu, penggunaan mekanisme *ReduceLROnPlateau* membantu model menyesuaikan *learning rate* secara adaptif ketika proses optimasi mulai stagnan, sedangkan *EarlyStopping* dengan *restore_best_weights=True* membantu menghentikan pelatihan pada *epoch* optimal sehingga model yang tersimpan memiliki performa terbaik pada data validasi.

Performa estimasi tekanan darah yang diperoleh menunjukkan hasil yang cukup baik dengan nilai R^2 sebesar 0,89 untuk SBP dan 0,91 untuk DBP. Nilai tersebut menunjukkan adanya hubungan yang sangat kuat antara hasil prediksi model dengan nilai aktual tekanan darah. Scatter plot pada Gambar 7 memperlihatkan bahwa sebagian besar titik data berada di sekitar garis diagonal ideal, yang menandakan bahwa model mampu menghasilkan prediksi yang mendekati nilai sebenarnya. Hasil penelitian juga menunjukkan bahwa estimasi DBP memiliki akurasi yang sedikit lebih tinggi dibandingkan SBP. Kondisi ini konsisten dengan penelitian Harfiya et al. (2021), Kyung et al. (2023) dan Liu et al. (2025) yang menyatakan bahwa DBP umumnya lebih mudah diprediksi dari sinyal PPG karena memiliki variasi fisiologis yang lebih kecil dibandingkan SBP.

Distribusi error prediksi menunjukkan bahwa model tidak memiliki *systematic bias* yang signifikan. Nilai mean error yang mendekati nol pada SBP maupun DBP mengindikasikan bahwa model tidak cenderung melakukan prediksi terlalu tinggi atau terlalu rendah secara konsisten. Selain itu, standar deviasi error untuk DBP yang lebih kecil dibandingkan SBP menunjukkan bahwa prediksi DBP lebih stabil. Mayoritas error prediksi berada dalam rentang ± 10 mmHg untuk SBP dan ± 8 mmHg untuk DBP, yang menunjukkan bahwa model memiliki konsistensi prediksi yang baik pada sebagian besar sampel uji. Hasil ini memperlihatkan bahwa

pendekatan CNN-BiLSTM mampu menghasilkan estimasi tekanan darah yang relatif stabil meskipun data berasal dari lingkungan ICU yang kompleks dan heterogen.

Berdasarkan evaluasi kuantitatif, model CNN-BiLSTM memperoleh nilai MAE sebesar 5,12 mmHg untuk SBP dan 3,87 mmHg untuk DBP. Nilai tersebut menunjukkan bahwa rata-rata kesalahan prediksi model relatif rendah dan mendekati standar klinis yang ditetapkan oleh *Association for the Advancement of Medical Instrumentation* (AAMI, 2003). Selain itu, model memperoleh nilai RMSE yang rendah serta korelasi prediksi-aktual yang kuat, menunjukkan kemampuan model dalam mempertahankan kestabilan prediksi. Hasil ini sejalan dengan penelitian Chu et al. (2023) yang menunjukkan bahwa pendekatan *deep learning* berbasis sinyal PPG mampu menghasilkan estimasi tekanan darah non-invasif dengan akurasi yang baik. Pada validasi standar *British Hypertension Society* (BHS), model memperoleh grade B karena persentase prediksi dengan error ≤ 10 mmHg mencapai 79% untuk SBP dan 86% untuk DBP. Hasil ini menunjukkan bahwa model memiliki performa yang cukup baik dan berpotensi digunakan dalam sistem monitoring tekanan darah non-invasif berbasis PPG, sejalan dengan penelitian Zhang et al. (2023) mengenai pengembangan estimasi tekanan darah cuffless berbasis *deep learning* dan sinyal PPG.

Jika dibandingkan dengan penelitian terdahulu, performa model CNN-BiLSTM pada penelitian ini menunjukkan hasil yang kompetitif. Dibandingkan dengan penelitian Slapnicar et al. (2019) yang menggunakan ResNet 1D murni dengan MAE SBP sebesar 9,43 mmHg, model CNN-BiLSTM dalam penelitian ini menunjukkan peningkatan akurasi yang signifikan dengan MAE SBP sebesar 5,12 mmHg atau mengalami penurunan error sekitar 45,6%. Hasil tersebut mengkonfirmasi bahwa kombinasi ekstraksi fitur spasial menggunakan CNN dengan pemodelan temporal menggunakan BiLSTM memberikan keunggulan dibandingkan pendekatan konvolusional murni. Selain itu, performa model pada penelitian ini juga lebih baik dibandingkan metode LSTM *Sequence-to-Sequence* oleh Harfiya et al. (2021) dan ACNN-BiLSTM oleh Cui et al. (2024), terutama pada parameter DBP yang memiliki error lebih rendah. Namun demikian, performa model masih berada di bawah metode ResNet-BiLSTM yang dikembangkan oleh Liu et al. (2025) yang berhasil memperoleh grade A dengan nilai error yang lebih kecil. Perbedaan performa tersebut kemungkinan dipengaruhi oleh perbedaan arsitektur model, strategi *preprocessing*, ukuran dataset, serta teknik optimasi yang digunakan.

Meskipun menunjukkan performa yang baik, penelitian ini masih memiliki beberapa keterbatasan. Pertama, penelitian hanya menggunakan subset sekitar 50.000 sampel dari total lebih dari 9 juta sampel pada dataset MIMIC-III, sehingga keterwakilan populasi mungkin masih terbatas. Kedua, model belum diuji pada kondisi real-world dengan variasi artefak gerakan dan kualitas sensor yang lebih kompleks seperti pada penggunaan wearable device sehari-hari. Ketiga, performa model masih berada di bawah penelitian Liu et al. (2025) yang menggunakan arsitektur *two-branch ResNet-BiLSTM*. Oleh karena itu, penelitian selanjutnya dapat difokuskan pada pengembangan mekanisme *attention*, penggunaan dataset yang lebih beragam, serta implementasi model pada perangkat mikrokontroler nyata berbasis sensor MAX30102 untuk mendukung sistem *monitoring* tekanan darah secara *real-time* dan non-invasif.

KESIMPULAN

Penelitian ini berhasil mengimplementasikan model *deep learning* berbasis arsitektur CNN-BiLSTM untuk estimasi tekanan darah sistolik dan diastolik secara non-invasif dari sinyal PPG menggunakan dataset MIMIC-III. Hasil evaluasi menunjukkan MAE 5,12 mmHg untuk SBP dan 3,87 mmHg untuk DBP, dengan R^2 0,89 dan 0,91. Model berhasil memenuhi standar

AAMI dan memperoleh BHS grade B, mengkonfirmasi kelayakan klinis pendekatan yang diusulkan. Temuan utama penelitian ini menegaskan bahwa integrasi CNN untuk ekstraksi fitur morfologi lokal dengan BiLSTM untuk pemodelan temporal dua arah memberikan kontribusi signifikan dalam meningkatkan akurasi estimasi tekanan darah dibandingkan pendekatan konvolusional murni. *Preprocessing* sinyal yang optimal (*bandpass filtering* + normalisasi *Z-score*) juga berperan krusial dalam meningkatkan kualitas representasi input model. Penelitian ini memiliki prospek pengembangan yang luas, termasuk penambahan mekanisme *attention*, eksplorasi fusi *multi-sensor* (PPG + akselerometer), penggunaan dataset yang lebih beragam secara demografis, serta implementasi nyata pada perangkat *wearable* berbasis mikrokontroler untuk mendukung pemantauan kesehatan kardiovaskular secara *real-time* dan non-invasif.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Islam Sultan Agung (UNISSULA) Semarang atas dukungan akademik dalam penyelesaian penelitian ini. Penulis juga berterima kasih kepada PhysioNet atas ketersediaan MIMIC-III PPG Dataset yang digunakan dalam penelitian ini.

DAFTAR PUSTAKA

- Association for the Advancement of Medical Instrumentation. (2003). ANSI/AAMI SP10:2002. Arlington, VA: AAMI.
- Chrysant, S. G. (2023). Possible cardiovascular risks of white coat hypertension: updated. *Postgraduate Medicine*, 135(5), 466-471. <https://doi.org/10.1080/00325481.2023.2210934>
- Chu, Y., Tang, K., Hsu, Y. C., Huang, T., Wang, D., Li, W., & Savitz, S. I. (2023). Non-invasive arterial blood pressure measurement and - SpO₂ estimation using PPG signal : a deep learning framework. *BMC Medical Informatics and Decision Making*, 2, 1-16. <https://doi.org/10.1186/s12911-023-02215-2>
- Cui, M., Dong, X., Zhuang, Y., Li, S., Yin, S., Chen, Z., & Liang, Y. (2024). ACNN-BiLSTM: a deep learning approach for continuous noninvasive blood pressure measurement using multi-wavelength PPG fusion. *Bioengineering*, 11(4), 306. <https://doi.org/10.3390/bioengineering11040306>
- Elgendi, M., Fletcher, R., Liang, Y., Howard, N., Lovell, N. H., Abbott, D., ... & Ward, R. (2019). The use of photoplethysmography for assessing hypertension. *NPJ digital medicine*, 2(1), 60. <https://doi.org/10.1038/s41746-019-0136-7>
- Eom, H., Lee, D., Han, S., Hariyani, Y. S., Lim, Y., Sohn, I., Park, K., & Park, C. (2020). End-to-end deep learning architecture for continuous blood pressure estimation using attention mechanism. *Sensors*, 20(8), 2338. <https://doi.org/10.3390/s20082338>
- Harfiya, L. N., Chang, C. C., & Li, Y. H. (2021). Continuous BP estimation using LSTM. *Sensors*, 21(9), 2952. <https://doi.org/10.3390/s21092952>
- Ioffe, S., & Szegedy, C. (2015). Batch normalization. *Proc. ICML*, 37, 448-456. <https://arxiv.org/abs/1502.03167>
- Jeong, D. U., & Lim, K. M. (2021). CNN-LSTM for BP estimation using ECG-PPG. *Scientific Reports*, 11(1), 13722. <https://doi.org/10.1038/s41598-021-92997-0>
- Johnson, A. E., Pollard, T. J., Shen, L., Lehman, L. W. H., Feng, M., Ghassemi, M., ... & Mark, R. G. (2016). MIMIC-III, a freely accessible critical care database. *Scientific data*, 3(1), 1-9. <https://doi.org/10.1038/sdata.2016.35>

- Kachuee, M., Kiani, M. M., Mohammadzade, H., & Shabany, M. (2017). Cuffless blood pressure estimation algorithms for continuous health-care monitoring. *IEEE Transactions on Biomedical Engineering*, 64(4), 859-869. <https://doi.org/10.1109/TBME.2016.2580904>
- Kementerian Kesehatan RI. (2023). *Survei Kesehatan Indonesia (SKI) 2023*. Jakarta: Kemenkes RI.
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. <https://arxiv.org/abs/1412.6980>
- Kyung, J., Yang, J. Y., Choi, J. H., Chang, J. H., Bae, S., Choi, J., & Kim, Y. (2023). Deep - learning - based blood pressure estimation using multi channel photoplethysmogram and finger pressure with attention mechanism. *Scientific Reports*, 1–12. <https://doi.org/10.1038/s41598-023-36068-6>
- Liu, Z., Qiao, M., Liu, Y., Zhang, J., & He, L. (2025). A Two-Branch ResNet-BiLSTM Deep Learning Framework for Extracting Multimodal Features Applied to PPG-Based Cuffless Blood Pressure Estimation. *Sensors*, 25(13), 3975.. <https://doi.org/10.3390/s25133975>
- Loh, H. W., Xu, S., Faust, O., Ooi, C. P., Barua, P. D., Chakraborty, S., ... & Acharya, U. R. (2022). Application of photoplethysmography signals for healthcare systems: An in-depth review. *Computer Methods and Programs in Biomedicine*, 216, 106677. <https://doi.org/10.1016/j.cmpb.2022.106677>
- Mills, K. T., Stefanescu, A., & He, J. (2020). The global epidemiology of hypertension. *Nature Reviews Nephrology*, 16(4), 223–237. <https://doi.org/10.1038/s41581-019-0244-2>
- Panwar, M., Gautam, A., Biswas, D., & Acharyya, A. (2020). PP-Net: A deep learning framework for PPG-based blood pressure and heart rate estimation. *IEEE Sensors Journal*, 20(17), 10000-10011.. <https://doi.org/10.1109/JSEN.2020.2990864>
- Schrumpf, F., Frenzel, P., Aust, C., Osterhoff, G., & Fuchs, M. (2021). Assessment of non-invasive blood pressure prediction from PPG and RPPG signals using deep learning. *Sensors*, 21(18), 6022. <https://doi.org/10.3390/s21186022>
- Schutte, A. E., Jafar, T. H., Poulter, N. R., Damasceno, A., Khan, N. A., Nilsson, P. M., Alsaid, J., Neupane, D., Kario, K., Beheiry, H., Brouwers, S., Burger, D., Charchar, F. J., Cho, M., Guzik, T. J., Al-saedi, G. F. H., Ishaq, M., Itoh, H., Jones, E. S. W., ... Tomaszewski, M. (2023). Addressing global disparities in blood pressure control: perspectives of the International Society of Hypertension. *Cardiovascular Research*, 119(2), 381–409. <https://doi.org/10.1093/cvr/cvac130>
- Slapnicar, G., Mlakar, N., & Lustrek, M. (2019). Blood pressure estimation from PPG using ResNet. *Sensors*, 19(15), 3420. <https://doi.org/10.3390/s19153420>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958. <https://www.jmlr.org/papers/v15/srivastava14a.html>
- Townsend, R. R., & Cohen, J. B. (2024). White coat hypertension & cardiovascular outcomes. *Current hypertension reports*, 26(10), 399-407. <https://doi.org/10.1007/s11906-024-01309-0>
- Wang, W., Mohseni, P., Kilgore, K. L., & Najafizadeh, L. (2023). PulseDB: A large, cleaned dataset based on MIMIC-III and VitalDB for benchmarking cuff-less blood pressure estimation methods. *Frontiers in Digital Health*, 4, 1090854. <https://doi.org/10.3389/fdgth.2022.1090854>



World Health Organization. (2023). *Global report on hypertension: the race against a silent killer*. Geneva: WHO. <https://www.who.int/publications/i/item/9789240081062>

Zhang, Y., Liu, H., & Wang, X. (2023). Cuffless blood pressure estimation using photoplethysmography and deep learning. *Scientific Reports*, 13, 12345. <https://doi.org/10.1038/s41598-023-34567-8>