

***Multivariate Time Series Forecasting Tanda Vital Pasien  
Unit Perawatan Intensif menggunakan Deep Learning***

**TUGAS AKHIR**

**Diajukan Untuk Melengkapi Salah Satu Syarat**

**Memperoleh Gelar Sarjana Komputer**



**OLEH :**

**Fernando Julian**

**09011381924087**

**JURUSAN SISTEM KOMPUTER**

**FAKULTAS ILMU KOMPUTER**

**UNIVERSITAS SRIWIJAYA**

**2022**

**LEMBAR PENGESAHAN**

***Multivariate Time Series Forecasting Tanda Vital Pasien Unit  
Perawatan Intensif menggunakan Deep Learning***

**Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sistem Komputer**

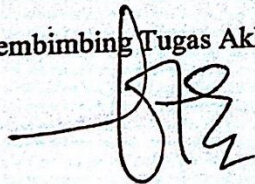
**OLEH :**

**Fernando Julian  
09011381924087**

**Palembang, <sup>2</sup> Januari 2023**

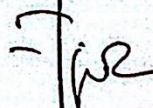
**Mengetahui,**

**Pembimbing Tugas Akhir 1**



**Dr. Ir. Bambang Tutuko, M.T.  
NIP. 196001121989031002**

**Pembimbing Tugas Akhir 2**

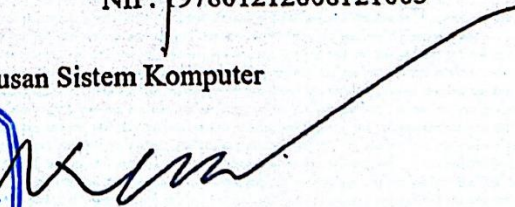


**Dr. Firdaus, S.T., M.Kom.  
NIP. 197801212008121003**

**Ketua Jurusan Sistem Komputer**



**Dr. Ir. H. Sukemi, M.T  
NIP. 196612032006041001**



## HALAMAN PERSETUJUAN

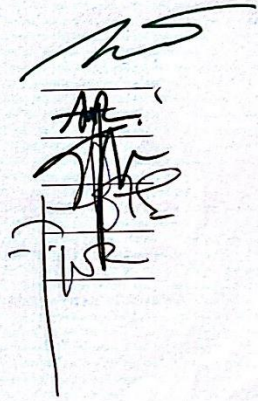
Telah diuji dan lulus pada:

Hari : Kamis

Tanggal : 5 Januari 2022


Tim Penguji:

1. Ketua : Rossi Passarella, S.T., M.Eng.
2. Sekretaris : Aditya Putra P Prasetyo, S.Kom., M.T.
3. Penguji : Prof. Dr. Ir. Siti Nurmaini, M.T.
4. Pembimbing 1 : Dr. Ir. Bambang Tutuko, M.T.
5. Pembimbing 2 : Dr. Firdaus, S.T., M.Kom.



Mengetahui, 2/2/23

Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.

NIP. 196612032006041001

## HALAMAN PERNYATAAN

Yang bertanda tangan dibawah ini:

Nama : Fernando Julian

NIM : 09011381924087

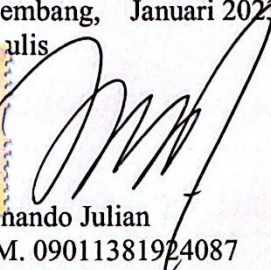
Judul : *Multivariate Time Series Forecasting* Tanda Vital Pasien Unit Perawatan Intensif menggunakan *Deep Learning*


Hasil Pengecekan Software Turnitin : 13%

Menyatakan bahwa laporan tugas akhir saya merupakan hasil karya sendiri dan bukan hasil penjiplakan atau plagiat. Apabila ditemukan unsur penjiplakan atau plagiat dalam laporan tugas akhir ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya

Demikian, pernyataan ini saya buat dalam keadaan sadar dan tanpa paksaan dari siapapun.



Palembang, Januari 2023  
Penulis  
  
Fernando Julian  
NIM. 09011381924087



## KATA PENGANTAR

Puji syukur kepada Allah SWT atas terselesaikannya penulisan laporan tugas akhir yang berjudul “*Multivariate Time Series Forecasting Tanda Vital Pasien Unit Perawatan Intensif menggunakan Deep Learning*”.

Ucapan terima kasih dari penulis untuk semua pihak yang telah membantu saya dalam menyelesaikan laporan tugas akhir ini terkhusus:

1. Allah SWT yang telah memberikan rahmat, nikmat, berkah yang melimpah kepada penulis sehingga dapat menyelesaikan laporan ini.
2. Orang tua tercinta, yaitu mama saya Nur Asia dan papa Yuliantoni yang telah mendukung saya dalam keadaan apapun.
3. Adik-adik saya, Anisa Ferananda dan Nico Prayoga yang terus memberikan dukungan moral kepada saya.
4. Bapak Dr. Ir. H. Sukemi, M.T., selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
5. Bapak Iman Saladin B. Azhar, S.Kom., M.MSI. selaku Dosen Pembimbing Akademik.
6. Bapak Dr. Firdaus, S.T., M.Kom. dan Bapak Dr. Ir. Bambang Tutuko, M.T. selaku Dosen Pembimbing saya yang telah meluangkan banyak waktunya dalam membimbing, memberikan saran dan motivasi kepada saya dalam menyelesaikan tugas akhir
7. Mbak Anggun, Mbak Ade, Kak Naufal, Mbak Annisa selaku mentor dan asisten laboratorium Intelligent System Research Group (ISysRG) yang telah membimbing, membantu, dan memotivasi untuk saya dalam menyelesaikan tugas akhir ini.
8. Intelligent System Research Group (ISysRG) atas bantuan infrastuktur dalam menyelesaikan Tugas Akhir.
9. Mbak Sari selaku admin Jurusan Sistem Komputer yang telah membantu mengurus seluruh berkas administrasi.

10. Teman-teman Sistem Komputer 2019, Grup Bacod Mobile, ACT Gaming, yang telah menjadi penghilang rasa lelah dalam menyelesaikan tugas akhir ini.

Saya sangat menyadari bahwa tugas akhir ini sangat jauh dari kata sempurna, sehingga diharapkan kritik dan saran yang membangun untuk memperbaiki penulisan saya kedepan. Semoga laporan ini dapat bermanfaat dan membantu bagi banyak orang.

Palembang, Desember 2022  
Penulis



Fernando Julian  
NIM. 09011381924087

*Multivariate Time Series Forecasting Vital Sign Intensive Care Unit Patient  
Using Deep Learning*

**FERNANDO JULIAN (09011381924087)**

*Computer Engineering Department, Computer Science Faculty, Sriwijaya University*

E-mail : nandokun69@gmail.com

**ABSTRACT**

The vital signs recorded by devices at the patient's bedside are commonly used in the medical field. Accurate monitoring of vital signs is crucial to ensure that the patient's health condition is improving or deteriorating. The commonly used vital signs are heart rate, blood pressure, blood oxygen saturation, respiratory rate, and body temperature. This research uses deep learning methods, such as Long Short-Term Memory (LSTM) and Bidirectional Long Short-Term Memory (Bi-LSTM), in processing data from the MIMIC-III database with batch size and learning rate configurations to produce the best configuration. The LSTM and Bi-LSTM models in the 60-minute data scenario and 30-minute prediction range produced the best RMSE value of 0.025615. In addition, this research also compares the handling of missing values in the dataset using two techniques: linear interpolation and autoencoder.

**Keywords:** Vital Signs, Long-Short Term Memory, Deep Learning, MIMIC Database, Multivariate

*Multivariate Time Series Forecasting Tanda Vital Pasien Unit Perawatan  
Intensif menggunakan Deep Learning*

**FERNANDO JULIAN (09011381924087)**

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

E-mail : nandokun69@gmail.com

**ABSTRAK**

Tanda-tanda vital yang direkam oleh perangkat disamping tempat tidur pasien adalah nilai yang biasa digunakan di bidang medis. Pemantauan tanda-tanda vital yang tepat dan akurat sangat penting untuk memastikan bahwa kondisi kesehatan pasien membaik atau memburuk. Tanda vital yang sering digunakan adalah denyut nadi, tekanan darah, saturasi oksigen darah, laju pernapasan, dan suhu tubuh. Penelitian menggunakan metode deep learning, seperti Long Short-Term Memory (LSTM) dan Bidirectional Long Short-Term Memory (BiLSTM) dalam pengolahan data dari database MIMIC-III dengan konfigurasi parameter batch size dan learning rate sehingga menghasilkan konfigurasi yang baik. Model LSTM dan BiLSTM pada skenario data 60 menit dan rentang prediksi 30 menit menghasilkan nilai RMSE terbaik yaitu 0,025615. Selain itu, penelitian ini juga membandingkan penanganan nilai yang hilang dalam dataset menggunakan dua teknik yaitu interpolasi linier dan autoencoder.

**Kata Kunci:** Tanda Vital, *Long-short term memory*, *Deep Learning*, *MIMIC Database*, *Multivariate*



## DAFTAR ISI

LEMBAR PENGESAHAN .....	I
HALAMAN PERSETUJUAN.....	II
HALAMAN PERNYATAAN .....	III
KATA PENGANTAR .....	IV
ABSTRACT.....	VI
ABSTRAK .....	VII
DAFTAR ISI.....	VIII
DAFTAR GAMBAR .....	XI
DAFTAR TABEL.....	XIII
BAB I PENDAHULUAN .....	1
1.1 Latar Belakang.....	1
1.2 Tujuan dan Manfaat.....	2
1.2.1 Tujuan .....	2
1.2.2 Manfaat .....	3
1.3 Rumusan Masalah .....	3
1.4 Batasan Masalah.....	3
1.5 Metodologi Penelitian .....	4
1.6 Sistematika Penelitian .....	5
BAB II TINJAUAN PUSTAKA.....	7
2.1 Penelitian Terkait.....	7
2.2 MIMIC-III .....	8
2.3 Tanda Vital .....	8
2.4 Time Series.....	9
2.5 Prakiraan (Forecasting) .....	9
2.6 Exploratory Data Analysis (EDA).....	10
2.7 Normalisasi Data .....	10
2.8 Imputasi Data.....	10
2.8.1 Interpolasi Linier.....	11
2.8.2 Machine Learning .....	12
2.9 Regresi.....	12
2.10 Deep Learning.....	13

2.10.1	Long Short Term Memory .....	13
2.10.2	Bidirectional Long Short Term Memory .....	17
2.11	Evaluasi Model .....	19
2.11.1	Mean Absolute Error (MAE) .....	19
2.11.2	Root Mean Square Error (RMSE).....	20
<b>BAB III</b>	<b>METODOLOGI PENELITIAN.....</b>	<b>21</b>
3.1	Pendahuluan .....	21
3.2	Kerangka Kerja.....	21
3.3	Data Acquisition (Akuisisi Data) .....	22
3.4	Preprocessing Data .....	23
3.4.1	Exploratory Data Analysis (EDA) .....	23
3.4.2	Data Cleaning.....	24
3.4.3	Data Normalization (Normalisasi Data).....	24
3.4.4	Data Imputation (Imputasi Data) .....	25
3.5	Split Data.....	26
3.6	Model Deep Learning.....	26
3.6.1	Long-Short Term Memory (LSTM).....	26
3.6.2	Bidirectional Long-Short Term Memory (BiLSTM).....	27
3.7	Evaluasi Model.....	27
<b>BAB IV</b>	<b>HASIL DAN PEMBAHASAN .....</b>	<b>28</b>
4.1	Pendahuluan .....	28
4.2	Database MIMIC-III.....	28
4.3	Akuisisi Data .....	29
4.4	EDA Sebelum Data Cleaning.....	29
4.5	Data Cleaning .....	34
4.5.1	Pencilan.....	34
4.5.2	Filterisasi Data Pasien .....	34
4.5.3	Pemisahan Berdasarkan Data Yang Berurutan .....	35
4.6	EDA Setelah Data Cleaning .....	37
4.6.1	Banyak Data.....	37
4.6.2	Sebaran Data .....	37
4.7	Split Data.....	41
4.8	Evaluasi Model.....	42
4.8.1	Fine Tuning .....	42

4.8.2	Hasil kinerja model dengan banyak data 15 menit dan rentang prediksi 30 menit.....	42
4.8.3	Hasil kinerja model dengan banyak data 15 menit dan rentang prediksi 60 menit.....	44
4.8.4	Hasil kinerja model dengan banyak data 15 menit dan rentang prediksi 120 menit.....	46
4.8.5	Hasil kinerja model dengan banyak data 60 menit dan rentang prediksi 30 menit.....	47
4.8.6	Hasil kinerja model dengan banyak data 60 menit dan rentang prediksi 60 menit.....	49
4.8.7	Hasil kinerja model dengan banyak data 60 menit dan rentang prediksi 120 menit (2 jam).....	50
4.8.9	Hasil kinerja model dengan banyak data 60 menit dan rentang prediksi 1440 menit (1 hari).....	53
4.9	Performa Model.....	56
4.10	Ringkasan Hasil Penelitian.....	59
BAB V KESIMPULAN.....		60
5.1	Pendahuluan.....	60
5.2	Kesimpulan.....	60
DAFTAR PUSTAKA.....		61
LAMPIRAN.....		64

## DAFTAR GAMBAR

<b>Gambar 2.1</b> Interpolasi Linier .....	11
<b>Gambar 2.2</b> Arsitektur Model LSTM.....	13
<b>Gambar 2.3</b> Forget Gate LSTM.....	14
<b>Gambar 2.4</b> Input Gate LSTM.....	15
<b>Gambar 2.5</b> Output Gate LSTM.....	16
<b>Gambar 2.6</b> Cara Kerja BiLSTM .....	18
<b>Gambar 2.7</b> Arsitektur BiLSTM.....	18
<b>Gambar 3.1</b> Kerangka Kerja.....	22
<b>Gambar 3.2</b> Akuisisi Data .....	23
<b>Gambar 3.3</b> Data Preprocessing .....	23
<b>Gambar 3.4</b> Normalisasi Data .....	25
<b>Gambar 3.5</b> Imputation Data .....	25
<b>Gambar 4.1</b> Sebaran data heartrate sebelum data cleaning .....	30
<b>Gambar 4.2</b> Sebaran data sysbp sebelum data cleaning .....	30
<b>Gambar 4.3</b> Sebaran data diasbp sebelum data cleaning.....	31
<b>Gambar 4.4</b> Sebaran data meanbp sebelum data cleaning.....	31
<b>Gambar 4.5</b> Sebaran data resprate sebelum data cleaning.....	32
<b>Gambar 4.6</b> Sebaran data tempc sebelum data cleaning .....	32
<b>Gambar 4.7</b> Sebaran data spo2 sebelum data cleaning.....	33
<b>Gambar 4.8</b> Sebaran data glucose sebelum data cleaning .....	33
<b>Gambar 4.9</b> Filterisasi Data Pasien.....	34
<b>Gambar 4.10</b> Pemisahan data berurutan.....	35
<b>Gambar 4.11</b> Perbandingan sebaran data heartrate .....	36
<b>Gambar 4.12</b> Perbandingan sebaran data sysbp .....	37
<b>Gambar 4.13</b> Perbandingan sebaran data diasbp.....	37
<b>Gambar 4.14</b> Perbandingan sebaran data meanbp.....	38
<b>Gambar 4.15</b> Perbandingan sebaran data tempc.....	38
<b>Gambar 4.16</b> Perbandingan sebaran data resprate.....	39
<b>Gambar 4.17</b> Perbandingan sebaran data spo2.....	39
<b>Gambar 4.18</b> Perbandingan sebaran data glucose .....	40

<b>Gambar 4.19</b> Perbandingan nilai aktual dan prediksi data 15– rentang prediksi 30 Data Validasi (a) dan data unseen (b) .....	43
<b>Gambar 4.19</b> Perbandingan nilai aktual dan prediksi data 15 menit – rentang prediksi 60 Data Validasi (a) dan data unseen (b) .....	45
<b>Gambar 4.21</b> Perbandingan nilai aktual dan prediksi data 15 menit – rentang prediksi 120 Data Validasi (a) dan data unseen (b) .....	46
<b>Gambar 4.22</b> Perbandingan nilai aktual dan prediksi data 60 menit – rentang prediksi 15 Data Validasi (a) dan data unseen (b) .....	48
<b>Gambar 4.25</b> Perbandingan nilai aktual dan prediksi data 60 menit – rentang prediksi 60 Data Validasi (a) dan data unseen (b) .....	49
<b>Gambar 4.19</b> Perbandingan nilai aktual dan prediksi data 60 menit – rentang prediksi 120 Data Validasi (a) dan data unseen (b) .....	51

## DAFTAR TABEL

<b>Tabel 3.1</b> Fine Tuning Hyperparameter .....	26
<b>Tabel 4.1</b> Database MIMIC-III.....	28
<b>Tabel 4.2</b> Akuisisi data tanda vital .....	29
<b>Tabel 4.3</b> Split Data.....	40
<b>Tabel 4.4</b> Hasil Fine Tuning.....	41
<b>Tabel 4.5</b> Kinerja model data 15 menit dan rentang prediksi 30 menit .....	42
<b>Tabel 4.6</b> Kinerja model data 15 menit dan rentang prediksi 30 menit per tanda vital menggunakan data interpolasi linier .....	42
<b>Tabel 4.7</b> Kinerja model dengan banyak data 15 menit dan rentang prediksi 60 menit menggunakan data interpolasi linier .....	43
<b>Tabel 4.8</b> Kinerja model data 15 menit dan rentang prediksi 60 menit per tanda vital.....	44
<b>Tabel 4.9</b> Kinerja model data 15 menit dan rentang prediksi 120 menit menggunakan interpolasi linier .....	45
<b>Tabel 4.10</b> Kinerja model data 15 menit dan rentang prediksi 120 menit per tanda vital.....	46
<b>Tabel 4.11</b> Kinerja model data 60 menit dan rentang prediksi 30 menit .....	47
<b>Tabel 4.12</b> Kinerja model data 60 menit dan rentang prediksi 30 menit per tanda vital.....	47
<b>Tabel 4.13</b> Kinerja model data 60 menit dan rentang prediksi 60 menit .....	48
<b>Tabel 4.14</b> Kinerja model data 60 menit dan rentang prediksi 60 menit per tanda vital.....	49
<b>Tabel 4.15</b> Kinerja model data 60 menit dan rentang prediksi 120 menit .....	50
<b>Tabel 4.16</b> Kinerja model data 60 menit dan rentang prediksi 120 menit per tanda vital.....	50
<b>Tabel 4.17</b> Evaluasi hasil model dengan banyak data 15 menit.....	51
<b>Tabel 4.18</b> Evaluasi hasil model dengan banyak data 60 menit.....	52
<b>Tabel 4.19</b> Performa model dengan banyak data 15 .....	53
<b>Tabel 4.20</b> Performa model dengan banyak data 60 .....	54
<b>Tabel 4.21</b> Model Terbaik .....	55

# BAB I PENDAHULUAN

## 1.1 Latar Belakang

*Multivariate time series* menjadi sumber utama untuk analisis dan peramalan data di berbagai bidang [1]. Misalnya, rangkaian gerakan layar sentuh telah digunakan untuk mengenali orang [2] urutan perilaku pengguna di jejaring sosial telah digunakan untuk rekomendasi [3], dan catatan pasien di rumah sakit biasanya direkam untuk memprediksi keadaan pasien di masa depan [4]. Seperti pemantauan data tanda vital [5]. Umumnya Tanda vital yang di rekam adalah tingkat pernafasan, saturasi oksigen, tekanan darah, suhu tubuh, dan denyut nadi yang bisa memberikan informasi penting untuk memantau kondisi seseorang [5].

Pemantauan tanda vital sebagai indikasi suatu kejadian sudah diperkenalkan di dunia industri medis lebih dari satu abad yang lalu [6]. Di setiap rumah sakit selalu merekam tanda vital dari setiap pasien *intensive care unit (ICU)*. Tanda-tanda vital yang tidak normal membantu untuk memperingatkan praktisi medis tentang potensi masalah kesehatan. Namun, masih banyak penelitian yang dibuat untuk meningkatkan kualitas performa secara klinis untuk *time series forecasting* tanda vital. Beberapa pendekatan *Time series forecasting* nilai tanda vital dibidang medis menggunakan *Machine Learning* [7][8]. Seperti, prakiraan polusi udara dapat membantu orang dalam mengambil tindakan pencegahan untuk mengurangi risiko penyakit yang disebabkan oleh menghirup udara yang tidak bersih [7]. *Forecasting* beban listrik [8]. *Time series forecasting* yang akurat dan stabil memainkan peran penting dalam berbagai aplikasi.

Namun pada penelitian [7][8] menimbulkan tantangan yang signifikan terhadap realisasi *time series forecasting* seperti volatilitas yang melekat dan ketidakstabilan data *time series* [9] dan *time series* mengandung banyak nilai yang hilang karena kesalahan selama pengumpulan data, kegagalan perangkat akuisisi, dan kesalahan manusia yang mengakibatkan hilangnya bagian dalam catatan pasien dan dapat memperburuk kinerja tindak lanjut pada rumah sakit [1]. Maka dari itu diperlukan metode imputasi untuk memasukkan nilai yang hilang. Banyak metode imputasi nilai hilang yang telah diusulkan untuk mengurangi pengaruh pada analisis

*time series* . Beberapa peneliti telah mengusulkan metode imputasi seperti pendekatan *deep learning* untuk memasukkan nilai yang hilang secara efektif selama training diusulkan untuk memaksimalkan hasil kinerja tindak lanjut di rumah sakit [10].

Beberapa pendekatan untuk model *deep learning*, seperti multi-layer perceptron neural network (MLP) [11], convolutional neural network (CNN) [12], long short-term memory network (LSTM) [13] dan deep belief neural network (DBN) [14], telah mendapat perhatian yang cukup besar dari para peneliti dan telah banyak digunakan dalam berbagai tugas *learning*, termasuk pengenalan citra dan *natural language processing*. Namun, untuk MLP dan DBN fokusnya adalah pada kumpulan data yang tidak berurutan [15]. Lain hal dengan CNN dan LSTM Karena kemampuan ekstraksi fitur yang unggul, *deep learning* telah memberikan kontribusi besar untuk meningkatkan akurasi *Multivariate Time series forecasting* [16]

Dari berbagai latar belakang masalah yang telah dibahas, maka dalam penelitian ini yang di usulkan pada tugas akhir ini untuk meningkatkan kinerja sistem menggunakan *Deep Learning* untuk membangun model *forecasting* agar menghasilkan kinerja yang baik dalam memprediksi nilai tanda vital pada pasien. Adapun judul dari tugas akhir ini, yaitu “*Multivariate Timeseries Forecasting Tanda Vital Pasien Unit Perawatan Intensif Menggunakan Deep Learning*”.

## **1.2 Tujuan dan Manfaat**

Adapun tujuan dan manfaat dari pengerjaan tugas akhir ini sebagai berikut:

### **1.2.1 Tujuan**

1. Memperbaiki penelitian sebelumnya mengenai prakiraan tanda vital yang hanya memprakira satu tanda vital.
2. Menemukan metode prediksi terbaik untuk memprediksi nilai tanda vital.



### **1.2.2 Manfaat**

1. Memberikan informasi tanda vital sedini mungkin dengan model prediksi terbaik menggunakan data yang ada.
2. Memberikan referensi untuk penelitian mengenai prediksi tanda vital.

### **1.3 Rumusan Masalah**

Untuk mendapatkan dataset yang ideal dilakukan data *pre-processing* dengan metode dan teknik yang disesuaikan agar dataset dapat cocok pada model arsitektur. Model arsitektur yang dihasilkan akan digunakan untuk menghasilkan nilai prediksi yang akan dibandingkan dengan hasil dari model arsitektur lainnya pada dataset yang digunakan. Hasil dari penelitian ini bagaimana meningkatkan kinerja sistem menggunakan *Deep Learning* untuk membangun model *time series forecasting* agar menghasilkan kinerja yang baik dalam memprediksi nilai tanda vital pada pasien.

### **1.4 Batasan Masalah**

Batasan masalah pada penelitian tugas akhir ini adalah sebagai berikut:

1. Penelitian dilakukan terhadap kasus tanda vital pada pasien unit perawatan intensif.
2. Penelitian ini menggunakan metode prakiraan nilai tanda vital dengan Deep Learning.
3. Model prakira dibangun menggunakan bahasa pemrograman Python.
4. Dataset tanda vital time series yang digunakan diambil dari data pasien yang masuk ke unit perawatan intensif di dalam database MIMIC-III.
5. Dataset yang digunakan menggunakan data time series regular.
6. Data yang kosong diisi dengan metode sederhana dan modern.
7. Penelitian ini menggunakan metode prakiraan nilai tanda vital dengan Deep Learning.
8. Penelitian ini menghasilkan nilai-nilai yang dapat mengukur performa metode yang digunakan berupa nilai Root Mean Square Error (RMSE) dan

Mean Absolute Error (MAE) dalam prakiraan nilai tanda vital dan nilai tanda vital sebenarnya

## **1.5 Metodologi Penelitian**

Pada Tugas Akhir ini, metodologi yang digunakan dalam melakukan penelitian adalah sebagai berikut:

### **1.5.1. Metode Studi Pustaka dan Literatur**

Sebelum memulai penelitian, penulis terlebih dahulu mempelajari data yang digunakan dari database yang didapatkan. Sehingga didapatkan dataset tanda vital yang akan digunakan untuk membangun model prakira. Arsitektur yang digunakan adalah arsitektur yang telah dikembangkan oleh peneliti-peneliti sebelumnya. Dengan menggunakan arsitektur yang telah dikembangkan, penulis dapat memahami dan menghasilkan model prakira yang baik.

### **1.5.2. Metode Konsultasi**

Metode ini melakukan konsultasi kepada pihak-pihak yang memiliki pengetahuan serta wawasan yang baik dalam mengatasi permasalahan yang ditemui pada penulisan tugas akhir.

### **1.5.3. Metode Eksperimental**

Penulis membuat program untuk membangun model arsitektur yang akan digunakan untuk mem-prakira nilai yang akan datang. Model yang telah dibangun dapat digunakan dengan diberikan sebuah dataset dan akan melakukan komputasi terhadap dataset sehingga menghasilkan nilai prakira.

Model yang dibuat akan menggunakan data yang akan dilatih dan di validasi dengan data yang bukan dari data yang akan dilatih. Setelah model dibangun, model akan dicoba menggunakan data yang bukan dari data yang akan dilatih ataupun Data Validasiasi.

### **1.5.4. Metode Hasil dan Analisa**

Hasil akhir dari pengerjaan tugas akhir dianalisis kualitas model yang telah dibangun dan seberapa lama waktu yang digunakan untuk model yang dilatih

sehingga didapatkan model prakira yang bagus dan ideal untuk mem-prakira nilai tanda vital. Hasil dari pengujian pada tugas akhir ini akan dianalisis kekurangannya, sehingga dapat digunakan untuk penelitian selanjutnya.

#### **1.5.5. Metode Penarikan Kesimpulan dan Saran**

Pada tahap ini, akan diperoleh kesimpulan dan saran yang dapat menjadi referensi untuk penelitian selanjutnya serta menjadi tahap akhir dari penelitian yang dilakuka

### **1.6 Sistematika Penelitian**

Adapun sistematika penulisan pada tugas akhir ini adalah sebagai berikut:

#### **BAB I PENDAHULUAN**

Pada bab ini akan ditulis mengenai penjelasan secara rinci mengenai latar belakang, tujuan dan manfaat, rumusan masalah, metodologi penelitian serta sistematika penulisan.

#### **BAB II TINJAUAN PUSTAKA**

Pada bab ini akan ditulis penjelasan mengenai dasar teori yang mengenai masalah-masalah di penelitian dalam tugas akhir ini.

#### **BAB III METODOLOGI PENELITIAN**

Pada bab ini akan ditulis penjelasan secara rinci mengenai alur proses, metode dan teknik yang digunakan dalam penelitian ini untuk mendapatkan model dan optimal.

#### **BAB IV HASIL DAN PEMBAHASAN**

Pada bab ini akan ditulis penjelasan secara rinci mengenai hasil dari penelitian yang telah dikerjakan dari proses, metode dan teknik yang digunakan.

#### **BAB V PENUTUP**

Pada bab ini akan ditulis penjelasan mengenai ringkasan dari hasil penelitian secara ringkas, jelas dan padat serta akan ditambahkan

saran untuk pengembangan penelitian selanjutnya dari hasil penelitian ini.

## DAFTAR PUSTAKA

- [1] Y. Zhang, B. Zhou, X. Cai, W. Guo, X. Ding, and X. Yuan, "Missing value imputation in multivariate time series with end-to-end generative adversarial networks," *Inf. Sci. (Ny)*, vol. 551, pp. 67–82, 2021, doi: 10.1016/j.ins.2020.11.035.
- [2] K. Rzecki, P. Pławiak, M. Niedźwiecki, T. Sońnicki, J. Leśkow, and M. Ciesielski, "Person recognition based on touch screen gestures using computational intelligence methods," *Inf. Sci. (Ny)*, vol. 415–416, pp. 70–84, 2017, doi: 10.1016/j.ins.2017.05.041.
- [3] S. Liu, Z. Chen, and X. Li, "Time-semantic-aware Poisson tensor factorization approach for scalable hotel recommendation," *Inf. Sci. (Ny)*, vol. 504, pp. 422–434, 2019, doi: 10.1016/j.ins.2019.07.068.
- [4] S. Xiao, J. Yan, M. Farajtabar, L. Song, X. Yang, and H. Zha, "Learning Time Series Associated Event Sequences with Recurrent Point Process Networks," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 30, no. 10, pp. 3124–3136, 2019, doi: 10.1109/TNNLS.2018.2889776.
- [5] S. Liu, J. Yao, and M. Motani, "Early Prediction of Vital Signs Using Generative Boosting via LSTM Networks," *Proc. - 2019 IEEE Int. Conf. Bioinforma. Biomed. BIBM 2019*, pp. 437–444, 2019, doi: 10.1109/BIBM47256.2019.8983313.
- [6] C. Sun, S. Hong, M. Song, J. Shang, and H. Li, "Personalized vital signs control based on continuous action-space reinforcement learning with supervised experience," *Biomed. Signal Process. Control*, vol. 69, no. 5, p. 102847, 2021, doi: 10.1016/j.bspc.2021.102847.
- [7] K. Alghatani, N. Ammar, A. Rezgui, and A. Shaban-Nejad, "Predicting intensive care unit length of stay and mortality using patient vital signs: Machine learning model development and validation," *JMIR Med. Informatics*, vol. 9, no. 5, 2021, doi: 10.2196/21347.
- [8] N. Kamel and Z. Baharudin, "Short term load forecast using burg autoregressive technique," *2007 Int. Conf. Intell. Adv. Syst. ICIAS 2007*, no. October, pp. 912–916, 2007, doi: 10.1109/ICIAS.2007.4658519.
- [9] S. Zhang, Y. Chen, W. Zhang, and R. Feng, "A novel ensemble deep learning model with dynamic error correction and multi-objective ensemble pruning for time series forecasting," *Inf. Sci. (Ny)*, vol. 544, pp. 427–445, 2021, doi: 10.1016/j.ins.2020.08.053.
- [10] C. Chen, Z. Hua, R. Zhang, G. Liu, and W. Wen, "Biomedical Signal Processing and Control Automated arrhythmia classification based on a combination network of CNN and LSTM," *Biomed. Signal Process. Control*, vol. 57, p. 101819, 2020, doi: 10.1016/j.bspc.2019.101819.
- [11] D. Liu, J. Wang, and H. Wang, "Short-term wind speed forecasting based on spectral clustering and optimised echo state networks," *Renew. Energy*,

- vol. 78, pp. 599–608, 2015, doi: 10.1016/j.renene.2015.01.022.
- [12] A. Ferreira and G. Giraldi, “Convolutional Neural Network approaches to granite tiles classification,” *Expert Syst. Appl.*, vol. 84, pp. 1–11, 2017, doi: 10.1016/j.eswa.2017.04.053.
- [13] J. Chen, G. Q. Zeng, W. Zhou, W. Du, and K. Di Lu, “Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization,” *Energy Convers. Manag.*, vol. 165, no. November 2017, pp. 681–695, 2018, doi: 10.1016/j.enconman.2018.03.098.
- [14] Y. Son *et al.*, “Automated artifact elimination of physiological signals using a deep belief network: An application for continuously measured arterial blood pressure waveforms,” *Inf. Sci. (Ny)*, vol. 456, pp. 145–158, 2018, doi: 10.1016/j.ins.2018.05.018.
- [15] Y. Luo, X. Cai, Y. Zhang, J. Xu, and X. Yuan, “Multivariate time series imputation with generative adversarial networks,” *Adv. Neural Inf. Process. Syst.*, vol. 2018-Decem, no. NeurIPS, pp. 1596–1607, 2018.
- [16] Y. Chen, S. Zhang, W. Zhang, J. Peng, and Y. Cai, “Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting,” *Energy Convers. Manag.*, vol. 185, no. November 2018, pp. 783–799, 2019, doi: 10.1016/j.enconman.2019.02.018.
- [17] A. Gensler, J. Henze, B. Sick, and N. Raabe, “Deep Learning for solar power forecasting - An approach using AutoEncoder and LSTM Neural Networks,” *2016 IEEE Int. Conf. Syst. Man, Cybern. SMC 2016 - Conf. Proc.*, pp. 2858–2865, 2017, doi: 10.1109/SMC.2016.7844673.
- [18] A. Sagheer and M. Kotb, “Time series forecasting of petroleum production using deep LSTM recurrent networks,” *Neurocomputing*, vol. 323, pp. 203–213, 2019, doi: 10.1016/j.neucom.2018.09.082.
- [19] D. A. Kristianto, F. Firdaus, and S. Sutarno, “PRAKIRAAN TANDA VITAL DARI DATA MULTIVARIATE TIME SERIES PASIEN UNIT PERAWATAN INTENSIF MENGGUNAKAN DEEP LEARNING,” 2022, [Online]. Available: <https://repository.unsri.ac.id/78605/>.
- [20] A. E. W. Johnson *et al.*, “Data Descriptor: MIMIC-III, a freely accessible critical care database,” 2016, doi: 10.1038/sdata.2016.35.
- [21] M. Scherpf, F. Gräber, H. Malberg, and S. Zaunseder, “Predicting sepsis with a recurrent neural network using the MIMIC III database,” *Comput. Biol. Med.*, vol. 113, no. June, p. 103395, 2019, doi: 10.1016/j.combiomed.2019.103395.
- [22] A. E. W. Johnson *et al.*, “MIMIC-III, a freely accessible critical care database,” *Sci. Data*, vol. 3, pp. 1–9, 2016, doi: 10.1038/sdata.2016.35.
- [23] J. Kellett and F. Sebat, “Make vital signs great again – A call for action,”

- Eur. J. Intern. Med.*, vol. 45, pp. 13–19, 2017, doi: 10.1016/j.ejim.2017.09.018.
- [24] M. Cardona-Morrell *et al.*, “Vital signs monitoring and nurse–patient interaction: A qualitative observational study of hospital practice,” *Int. J. Nurs. Stud.*, vol. 56, pp. 9–16, 2015, doi: 10.1016/j.ijnurstu.2015.12.007.
- [25] S. Panigrahi and H. S. Behera, “A hybrid ETS–ANN model for time series forecasting,” *Eng. Appl. Artif. Intell.*, vol. 66, no. June, pp. 49–59, 2017, doi: 10.1016/j.engappai.2017.07.007.
- [26] M. Ahsan, M. Mahmud, P. Saha, K. Gupta, and Z. Siddique, “Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance,” *Technologies*, vol. 9, no. 3, p. 52, 2021, doi: 10.3390/technologies9030052.
- [27] F. Firdaus, B. Tutuko, and W. R. Aissy, “Multivariate Imputation Tanda Vital Pasien Unit Perawatan Intensif Menggunakan Autoencoder,” 2022.
- [28] A. Schneider, G. Hommel, and M. Blettner, “Lineare regressionsanalyse - Teil 14 der serie zur bewertung wissenschaftlicher publikationen,” *Dtsch. Arztebl.*, vol. 107, no. 44, pp. 776–782, 2010, doi: 10.3238/arztebl.2010.0776.
- [29] C. Olah, “Understanding LSTM Networks. Understanding LSTM Networks,” 2015.
- [30] L. Jiang, C. Yan, X. Zhang, B. Zhou, T. Cheng, and J. Zhao, “ScienceDirect Temperature prediction of battery energy storage plant based on,” *Energy Reports*, vol. 8, pp. 1009–1018, 2022, doi: 10.1016/j.egy.2022.02.195.
- [31] J. Ju and F. A. Liu, “Multivariate time series data prediction based on ATT-LSTM network,” *Appl. Sci.*, vol. 11, no. 20, 2021, doi: 10.3390/app11209373.
- [32] H. Widiputra, A. Mailangkay, and E. Gautama, “Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction,” *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/9903518.
- [33] F. Firdaus, B. Tutuko, and W. R. Aissy, “Multivariate Imputing Data Tanda Vital Pasien Perawatan Unit Intensif menggunakan Autoencoder,” 2022.
- [34] Guinness World Records, “Highest blood sugar level,” 2008. <https://www.guinnessworldrecords.com/world-records/highest-blood-sugar-level>.