

***Multivariate Imputation Tanda Vital Pasien Unit  
Perawatan Intensif menggunakan Convolutional Neural  
Network***

**SKRIPSI**

**Diajukan Untuk Melengkapi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer**



**OLEH :**

**WIDYA ROHADATUL AIS'SY**

**09011281924035**

**JURUSAN SISTEM KOMPUTER  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS SRIWIJAYA**

**2023**

**LEMBAR PENGESAHAN**

***Multivariate Imputation Tanda Vital Pasien Unit Perawatan  
Intensif menggunakan Convolutional Neural Network***

**SKRIPSI**

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

Oleh:

**WIDYA ROHADATUL AIS'SY  
09011281924035**

**Palembang, Mei 2023**

Mengetahui,

Pembimbing Tugas Akhir 1

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

Pembimbing Tugas Akhir 2

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

Ketua Jurusan Sistem Komputer 17/5/23



Dr. Ir. H. Sukemi, M.T

NIP. 196612032006041001

## HALAMAN PERSETUJUAN



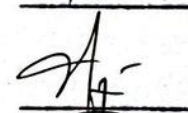

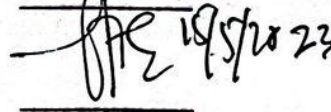
Telah diuji dan lulus pada :

Hari : Kamis

Tanggal : 13 April 2023

Tim Penguji :

1. Ketua : Huda Ubaya, M.T.
2. Sekretaris : Muhammad Ali Buchari, S.Kom, M.T.
3. Penguji : Prof. Ir. Siti Nurmaini, M.T., Ph.D.
4. Pembimbing 1: Dr. Firdaus, S.T., M.Kom.
5. Pembimbing 2: Dr. Ir. Bambang Tutuko, M.T.

  
\_\_\_\_\_  
  
\_\_\_\_\_  
  
\_\_\_\_\_  
  
\_\_\_\_\_  
  
\_\_\_\_\_  
18/5/2023

Mengetahui,

Ketua Jurusan Sistem Komputer



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

**NIP. 196612032006041001**

## HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Widya Rohadatul Ais'sy

NIM : 09011281924031

Judul : *Multivariate Imputation* Tanda Vital Pasien Unit Perawatan Intensif menggunakan *Convolutional Neural Network*

Hasil Pengecekan Software Turnitin : 11%

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, Mei 2023



Widya Rohadatul Ais'sy

NIM. 09011281924035



## KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh, Puji dan syukur atas kehadiran Allah SWT yang telah melimpahkan rahmat, kasih sayang dan karunia-Nya, sehingga penulis dapat menyelesaikan laporan Tugas Akhir dengan judul "Multivariate Imputation Tanda Vital Pasien Unit Perawatan Intensif menggunakan Convolutional Neural Network".

Selama pembuatan Tugas Akhir dan penulisan laporan Tugas Akhir ini, penulis banyak mendapatkan bantuan dan peran serta dari semua pihak, baik secara langsung maupun tak langsung. Oleh karena itu, pada kesempatan ini penulis menyampaikan ucapan terima kasih kepada :

1. Allah SWT yang telah melimpahkan berkah serta nikmat kesehatan dan kesempatan kepada penulis dalam mengerjakan Tugas Akhir.
2. Kedua orang tua, saudara, dan keluarga besar yang telah mendoakan dan memberikan motivasi serta support.
3. Bapak Dr. Ir. Sukemi, M.T. selaku Ketua Jurusan Sistem Komputer Universitas Sriwijaya.
4. Bapak Dr. Firdaus, S.T., M.Kom. dan Dr. Ir. Bambang Tutuko, M.T. selaku Pembimbing Tugas Akhir yang selalu mengarahkan dan memberi saran terkait penyusunan Tugas Akhir ini serta memberikan motivasi dan ilmu yang pastinya akan berguna untuk penulis.
5. Ibu Prof. Dr. Ir Siti Nurmaini, M.T. selaku Head of Intelligent System Research Group (ISysRG) yang telah memberi kesempatan besar untuk menjadi bagian dari team research group ini.
6. Intelligent System Research Group (ISysRG) atas bantuan infrastruktur dalam menyelesaikan tugas akhir.
7. Bapak Rossi Passarella, S.T., M.Eng. selaku Dosen Pembimbing Akademik di Jurusan Sistem Komputer Universitas Sriwijaya.
8. Mbak Anggun Islami dan Fernando Julian dalam membantu pembuatan Tugas Akhir ini
9. Mbak Ade Iriani Safitri, Mbak Annisa Darmawahyuni dan Kak Naufal Rachmatullah sebagai mentor di ISysRG.

10. KLF yang tidak bisa disebutkan dalam pengisi hari-hari dalam membuat laporan akhir ini
11. Rekan seperjuangan di group ISysRG yang selalu membantu dalam pengerjaan Tugas Akhir ini.
12. Mbak Renny selaku Administrasi Jurusan Sistem Komputer yang telah membantudalam proses administrasi terkait Tugas Akhir.
13. Kakak tingkat dan teman-teman Sistem Komputer angkatan 2019 yang telah memberikan bantuan selama pengerjaan Tugas Akhir.

Pada laporan Tugas Akhir ini, penulis menyadari masih banyak kekurangan yang perlu diperbaiki, karenanya penulis mengharapkan kritik dan saran dari semua pihak untuk perbaikan agar menjadi lebih baik. Semoga laporan Tugas Akhir ini dapat bermanfaat dan dapat menjadi referensi untuk penelitian selanjutnya.

Wassalamu'alaikum Warrahmatullahi Wabarakatuh.

Penulis



Widya Rohadatul Ais'sy

**Multivariate Imputation Tanda Vital Pasien Unit Perawatan Intensif  
menggunakan *Convolutional Neural Network***

**WIDYA ROHADATUL AIS'SY (09011281924035)**

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

Email : [widyarohadatull@gmail.com](mailto:widyarohadatull@gmail.com)

**ABSTRAK**

Data yang hilang adalah masalah umum dalam kumpulan data tanda vital dan merupakan salah satu topik paling yang kompleks dalam ilmu komputer. Karena banyaknya nilai yang hilang pada data tersebut, membuat lebih sulit dalam melakukan pengolahan data. Sehingga, salah satu cara untuk mengatasi data yang hilang dengan Menggunakan imputasi. Imputasi data tanda vital merupakan proses mengisi data yang hilang atau tidak lengkap pada catatan medis pasien. Machine learning untuk imputasi data telah sering diterapkan, tetapi cenderung menghasilkan kinerja yang buruk dengan dataset yang memiliki nilai yang hilang tinggi. Sehingga, digunakan metode deep learning, karena terbukti memiliki kemampuan untuk menggali dan menangkap informasi yang tersembunyi dalam data yang membuat kemajuan dalam imputasi data. Salah satu metode yang digunakan untuk imputasi data tanda vital adalah Autoencoder dan Convolutional Neural Network (CNN). Penelitian-penelitian terbaru menunjukkan bahwa CNN dan Autoencoder adalah dua metode yang cukup efektif dalam melakukan imputasi data tanda vital. Pada penelitian ini, akan dibandingkan performa antara metode Autoencoder dan CNN dalam imputasi data tanda vital pada medical information mart for intensive care III (MIMIC III) database. Pada CNN menghasilkan nilai RMSE paling kecil yaitu 0.0306 sedangkan pada Autoencoder menghasilkan nilai RMSE paling kecil yaitu 0.0642. Hasil imputasi data tanda vital menggunakan CNN menunjukkan hasil yang lebih unggul dari pada hasil Autoencoder.

**Keywords** : Imputasi, Tanda Vital, nilai yang hilang, MIMIC Basis Data, *Autoencoder, Convolutional Neural Network (CNN)*

***Multivariate Imputation of Vital Signs in Intensive Care Unit Patients Using  
Convolutional Neural Network***

**WIDYA ROHADATUL AIS'SY (09011281924035)**

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

*Email : [widyarohadatull@gmail.com](mailto:widyarohadatull@gmail.com)*

**ABSTRACT**

*Missing data is a common problem in vital sign datasets and is one of the most complex topics in computer science. The large number of missing values in the data makes it more difficult to process. Therefore, one way to address missing data is through imputation. Vital sign data imputation is the process of filling in missing or incomplete data in a patient's medical records. Machine learning for data imputation has been frequently applied, but tends to perform poorly with datasets that have high levels of missing values. Hence, deep learning methods are used, as they have the ability to unearth and capture hidden information in data that leads to progress in data imputation. One of the methods used for vital sign data imputation is the Autoencoder and Convolutional Neural Network (CNN). Recent studies have shown that CNN and Autoencoder are two methods that are quite effective in performing vital sign data imputation. In this study, the performance between Autoencoder and CNN methods in imputing vital sign data in the medical information mart for intensive care III (MIMIC III) database will be compared. The CNN resulted in the smallest RMSE value of 0.0306 while the Autoencoder resulted in the smallest RMSE value of 0.0642. The results of vital sign data imputation using CNN showed superior performance compared to Autoencoder.*

**Keywords :** *Imputation, Vital Sign, Missing Value, MIMIC Database, Autoencoder, Convolutional Neural Network (CNN)*



## DAFTAR ISI

<b>LEMBAR PENGESAHAN .....</b>	<b>ii</b>
<b>HALAMAN PERSETUJUAN.....</b>	<b>iii</b>
<b>HALAMAN PERNYATAAN.....</b>	<b>iv</b>
<b>KATA PENGANTAR.....</b>	<b>v</b>
<b>ABSTRAK .....</b>	<b>vii</b>
<b>ABSTRACT .....</b>	<b>vii</b>
<b>DAFTAR ISI.....</b>	<b>ix</b>
<b>DAFTAR GAMBAR.....</b>	<b>xiii</b>
<b>DAFTAR TABEL.....</b>	<b>xiii</b>
<b>BAB I.....</b>	<b>1</b>
<b>PENDAHULUAN.....</b>	<b>1</b>
1.1. Latar Belakang .....	1
1.2. Tujuan Penelitian .....	2
1.3. Perumusan Masalah .....	3
1.4. Metodologi Penelitian .....	3
1.4.1. Metode Studi Pustaka dan Literatur.....	3
1.4.2. Metode Konsultasi .....	3
1.4.3. Metode Pembuatan Model.....	3
1.4.4. Metode Pengujian dan Validasi .....	3
1.4.5. Metode Hasil dan Analisa.....	3
1.4.6. Metode Penarikan Kesimpulan dan Saran .....	4
1.5. Sistematika Penulisan.....	4
<b>BAB II .....</b>	<b>6</b>
<b>TINJAUAN PUSTAKA .....</b>	<b>6</b>
2.1. Basis Data.....	6
2.2. Tanda Vital Pasien Unit Perawatan Intensif .....	7
2.3. Data Time Series .....	7
2.4. Imputasi Data .....	8
2.5. Imputasi Multivariat.....	9
2.6. Autoencoder .....	9

2.7.	Convolutional Neural Network U-Net .....	10
2.8.	Learning Rate Schedule .....	12
2.9.	Exponential Decay .....	12
2.10.	Evaluasi Model.....	13
2.10.1.	Mean Squared Error.....	14
2.10.2.	Root Mean Squared Error.....	14
<b>BAB III</b>	.....	<b>15</b>
<b>METODOLOGI PENELITIAN</b>	.....	<b>15</b>
3.1.	Kerangka Kerja .....	15
3.2.	Akuisisi Data.....	17
3.3.	Basis Data MIMIC-III.....	18
3.4.	Hasil Akuisisi Data .....	19
3.5.	Pra-Pengolahan Data.....	19
3.5.1.	Menghilangkan Data dengan Nilai yang hilang .....	20
3.5.2.	Normalisasi Data.....	21
3.5.3.	Pembagian Data .....	22
3.5.5.	Pembuatan Nilai Hilang Buatan (Artificial NaN).....	23
3.4.5.1.	Data Label .....	23
3.4.5.2.	Data NaN.....	24
3.4.5.3.	Imputasi Nilai yang Hilang .....	24
3.4.5.4.	Data Mask .....	25
3.6.	Hasil Pra-Pengolahan Data .....	25
3.7.	Multivariate Imputation Data.....	26
3.7.1.	Autoencoder.....	26
3.7.2.	Convolutional Neural Network U-Net.....	27
3.8.	Evaluasi Kinerja Model.....	28
<b>BAB IV</b>	.....	<b>29</b>
<b>HASIL DAN ANALISA</b>	.....	<b>29</b>
4.1.	Hasil Imputasi dengan Arsitektur Autoencoder .....	29
4.1.1.	Hasil Imputasi Data dengan segment 10 Batch Size 16 .....	29
4.1.2.	Hasil Imputasi Data dengan segment 10 Batch Size 32 .....	30
4.1.3.	Hasil Imputasi Data dengan Segment 15 Batch Size 16.....	31

4.1.4.	Hasil Imputasi Data dengan segment 15 Batch Size 32 .....	32
4.1.5.	Hasil Imputasi Data dengan segment 20 Batch Size 16 .....	33
4.1.6.	Hasil Imputasi Data dengan segment 20 Batch Size 32 .....	34
4.1.7.	Hasil Imputasi Data dengan segment 30 Batch Size 16 .....	35
4.1.8.	Hasil Imputasi Data dengan segment 30 Batch Size 32 .....	36
4.1.9.	Hasil Imputasi Data dengan segment 40 Batch Size 16 .....	37
4.1.10.	Hasil Imputasi Data dengan segment 40 Batch Size 32 .....	38
4.1.11.	Hasil Imputasi Data dengan segment 50 Batch Size 16 .....	39
4.1.12.	Hasil Imputasi Data dengan segment 50 Batch Size 32 .....	40
4.1.13.	Hasil Imputasi Data dengan segment 60 Batch Size 16 .....	41
4.1.14.	Hasil Imputasi Data dengan segment 60 Batch Size 32 .....	42
4.2.	Hasil Imputasi dengan Arsitektur CNN .....	43
4.2.1.	Hasil Imputasi dengan segment 8 Batch Size 16 .....	43
4.2.2.	Hasil Imputasi dengan segment 8 Batch Size 32 .....	44
4.2.3.	Hasil Imputasi dengan segment 32 Batch Size 16 .....	45
4.2.4.	Hasil Imputasi dengan segment 32 Batch Size 32 .....	47
4.2.5.	Hasil Imputasi dengan segment 64 Batch Size 16 .....	48
4.2.6.	Hasil Imputasi dengan segment 64 Batch Size 32 .....	51
4.3.	Analisis imputasi data berdasarkan epoch 25 dan epoch 50 .....	54
4.3.1.	Hasil dan analisis imputasi data menggunakan Autoencoder berdasarkan epoch 25 .....	54
4.3.2.	Hasil dan analisis imputasi data menggunakan Autoencoder berdasarkan epoch 50 .....	55
4.3.3.	Hasil dan analisis imputasi data menggunakan CNN berdasarkan epoch 25 .....	56
4.3.4.	Hasil dan analisis imputasi data menggunakan CNN berdasarkan epoch 50 .....	57
4.4.	Analisa Nilai RMSE Terbaik dari Autoencoder dan CNN .....	57
4.5.	Analisis imputasi data berdasarkan tanda-tanda vital pada arsitektur Autoencoder .....	60
4.6.	Analisis imputasi data berdasarkan tanda-tanda vital pada arsitektur CNN .....	61

4.7.	Resume.....	62
4.7.1.	Model Terbaik Autoencoder.....	62
4.7.2.	Model Terbaik CNN.....	62
<b>BAB V</b>	.....	<b>63</b>
<b>KESIMPULAN</b>	.....	<b>63</b>
5.1.	Kesimpulan.....	63
5.2.	Saran.....	63
<b>DAFTAR PUSTAKA</b>	.....	<b>64</b>

## DAFTAR GAMBAR

<b>Gambar 2. 1</b> Arsitektur Autoencoder .....	10
<b>Gambar 2. 2</b> Arsitektur CNN.....	11
<b>Gambar 2. 3</b> Grafik Exponential Decay .....	13
<b>Gambar 3. 1</b> Kerangka Kerja.....	16
<b>Gambar 3. 2</b> Tabel chartevents MIMIC-III .....	17
<b>Gambar 3. 3</b> Sample data tanda vital pasien ICU .....	18
<b>Gambar 3. 4</b> Pra-Pengolahan Data .....	20
<b>Gambar 3. 5</b> Sample data setelah nilai NaN dibersihkan .....	21
<b>Gambar 3. 6</b> Normalisasi Data .....	21
<b>Gambar 3. 7</b> Contoh data label .....	23
<b>Gambar 3. 8</b> Contoh posisi nilai NaN pada data NaN.....	24
<b>Gambar 3. 9</b> Nilai yang hilang diisi dengan metode rata-rata .....	25
<b>Gambar 3. 10</b> Contoh data mask .....	25
<b>Gambar 4. 1</b> Grafik Hasil RMSE Segment 10 Batch Size 16 .....	30
<b>Gambar 4. 2</b> Grafik Hasil RMSE Segment 15 Batch Size 16 .....	32
<b>Gambar 4. 3</b> Grafik Hasil RMSE Segment 20 Batch Size 16 .....	34
<b>Gambar 4. 4</b> Grafik Hasil RMSE Segment 30 Batch Size 16 .....	36
<b>Gambar 4. 5</b> Grafik Hasil RMSE Segment 40 Batch Size 16 .....	38
<b>Gambar 4. 6</b> Grafik Hasil RMSE Segment 50 Batch Size 16 .....	40
<b>Gambar 4. 7</b> Grafik Hasil RMSE Segment 60 Batch Size 16 .....	42
<b>Gambar 4. 8</b> Grafik Hasil RMSE Segment 8 Batch Size 16 .....	44
<b>Gambar 4. 9</b> Grafik Hasil RMSE Segment 32 Batch Size 16 Epoch 50 .....	46
<b>Gambar 4. 10</b> Grafik Hasil RMSE Segment 64 Batch Size 16 Epoch 50 .....	51
<b>Gambar 4. 11</b> Grafik Hasil RMSE Segment 8 .....	59
<b>Gambar 4. 12</b> Grafik Hasil RMSE Segment 32 .....	59
<b>Gambar 4. 13</b> Grafik Hasil RMSE Segment 64 .....	60

## DAFTAR TABEL

<b>Tabel 3. 1</b>	Tabel pada database MIMIC-III.....	18
<b>Tabel 3. 2</b>	Total data pada setiap kolom tanda vital pasien ICU.....	19
<b>Tabel 3. 3</b>	Pembagian data train dan data valid.....	22
<b>Tabel 3. 4</b>	Nilai Min dan Max setelah menghilangkan Nilai NaN.....	26
<b>Tabel 3. 5</b>	Hyperparameter model pada arsitektur Autoencoder.....	27
<b>Tabel 3. 6</b>	Hyperparameter model pada arsitektur CNN.....	28
<b>Tabel 4. 1</b>	RMSE dengan segment 10 Batch Size 16.....	29
<b>Tabel 4. 2</b>	RMSE dengan segment 10 Batch Size 32.....	30
<b>Tabel 4. 3</b>	RMSE dengan segment 15 Batch Size 16.....	31
<b>Tabel 4. 4</b>	RMSE dengan segment 15 Batch Size 32.....	32
<b>Tabel 4. 5</b>	RMSE dengan segment 20 Batch Size 16.....	33
<b>Tabel 4. 6</b>	RMSE dengan segment 20 Batch Size 32.....	34
<b>Tabel 4. 7</b>	RMSE dengan segment 30 Batch Size 16.....	35
<b>Tabel 4. 8</b>	RMSE dengan segment 30 Batch Size 32.....	36
<b>Tabel 4. 9</b>	RMSE dengan segment 40 Batch Size 16.....	37
<b>Tabel 4. 10</b>	RMSE dengan segment 40 Batch Size 32.....	38
<b>Tabel 4. 11</b>	RMSE dengan segment 50 Batch Size 16.....	39
<b>Tabel 4. 12</b>	RMSE dengan segment 50 Batch Size 32.....	40
<b>Tabel 4. 13</b>	RMSE dengan segment 60 Batch Size 16.....	41
<b>Tabel 4. 14</b>	RMSE dengan segment 60 Batch Size 32.....	42
<b>Tabel 4. 15</b>	RMSE dengan segment 8 Batch Size 16.....	43
<b>Tabel 4. 16</b>	RMSE dengan segment 8 Batch Size 32.....	44
<b>Tabel 4. 17</b>	RMSE dengan segment 32 Batch Size 16.....	45
<b>Tabel 4. 18</b>	RMSE dengan segment 32 Batch Size 32.....	47
<b>Tabel 4. 19</b>	RMSE dengan segment 64 Batch Size 16.....	48
<b>Tabel 4. 20</b>	RMSE dengan segment 64 Batch Size 32.....	51
<b>Tabel 4. 21</b>	Hasil RMSE berdasarkan epoch 25 Arsitektur Autoencoder.....	54
<b>Tabel 4. 22</b>	Hasil RMSE berdasarkan epoch 50 Arsitektur Autoencoder.....	55
<b>Tabel 4. 23</b>	Hasil RMSE berdasarkan epoch 25 Arsitektur CNN.....	56
<b>Tabel 4. 24</b>	Hasil RMSE berdasarkan epoch 50 Arsitektur CNN.....	57



<b>Tabel 4. 25</b>	Analisa Nilai RMSE Terbaik dari Autoencoder dan CNN .....	58
<b>Tabel 4. 26</b>	Hasil RMSE dari tanda-tanda vital Autoencoder .....	60
<b>Tabel 4. 27</b>	Hasil RMSE dari tanda-tanda vital CNN .....	61

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang

Dalam proses pengolahan data, seringkali terjadi beberapa nilai yang hilang atau tidak lengkap pada dataset yang digunakan. Kondisi tersebut dapat disebabkan oleh beberapa faktor, seperti kesalahan pengukuran, kegagalan sistem saat merekam data, atau penghapusan sengaja karena alasan tertentu. Namun, keberadaan nilai yang hilang tersebut dapat sangat mempengaruhi kualitas analisis data dan keputusan yang diambil. Oleh karena itu, teknik imputasi data menjadi sangat penting dalam proses pengolahan data, yang bertujuan untuk mengisi nilai yang hilang pada dataset dengan menggunakan teknik tertentu agar data yang digunakan dapat lebih akurat dan valid.

Saat ini nilai hilang adalah masalah yang sering ditemukan dalam datasets dan dapat menurunkan kinerja sebagian besar model *machine learning* [4]. Maka diperlukannya pendekatan *deep learning* untuk imputasi nilai yang hilang. Beberapa penelitian yang melakukan pengisian nilai-nilai yang hilang secara umum dapat dirujuk pada literature, seperti Pada penelitian [5]-[6]-[7] yang memiliki masalah nilai yang hilang menggunakan *linear imputation* (LI), *predictive mean matching* (PMM), *random forest* (RF), *k-nearest neighbours* (k-NN) dan *Kalman smoothing* pada metode *structural time series* (Kalman) [5], *logistic regression* [6], RNN [7]-[11]. Namun pada [10] memperkirakan nilai yang hilang dalam data time series IoT menggunakan tiga algoritma interpolasi yaitu *Radial Basis Functions*, *Moving Least Squares (MLS)*, *Adaptive Inverse Distance Weighted* dan hasil dari *Moving Least Squares (MLS)* adalah yang terbaik. Pada penelitian [12] [13] melakukan pengisian nilai-nilai yang hilang pada data tanda vital dengan *machine Learning*. Penelitian tersebut menghasilkan nilai RMSE yang cukup baik.

Pada beberapa penelitian, penggunaan Autoencoder untuk imputasi data yang hilang memiliki hasil yang sangat baik [14][15][16]. Autoencoder yaitu model neural network yang memiliki input dan output yang sama. Autoencoder mempelajari data input dan berusaha untuk melakukan rekonstruksi terhadap data input tersebut. Metode ini menyediakan strategi imputasi dari setiap layer yang

dipakainya untuk mengimputasi data hilang tersebut. Karena terbukti dari berbagai penelitian yaitu Pada penelitian prediksi data genom [17] dan prediksi solar yield [18] melakukan teknik imputasi untuk menangani data yang hilang pada data tersebut dengan metode Variasi Autoencoder (VAE) yang menghasilkan kinerja yang baik

Pada penelitian [19] menggunakan CNN dapat mempelajari fitur-fitur penting dari data tanda vital dan menghasilkan imputasi yang akurat dan efektif. Hasil penelitian menunjukkan bahwa teknik ini dapat meningkatkan kualitas data dengan tingkat keberhasilan mencapai 97,44% untuk tekanan darah sistolik dan 96,75% untuk tekanan darah diastolik. Oleh karena itu, teknik imputasi data tanda vital menggunakan CNN dapat menjadi solusi yang efektif dalam meningkatkan akurasi diagnosis dan keputusan medis.

Berdasarkan berbagai latar belakang masalah yang telah dibahas, penelitian ini akan mengembangkan model imputasi data vital dengan menggunakan dua metode yaitu Autoencoder dan CNN. Tujuan dari penelitian ini adalah untuk meningkatkan kualitas hasil dari imputasi data tanda vital pasien unit perawatan intensif dengan judul "Multivariate Imputasi Tanda Vital Pasien Unit Perawatan Intensif Menggunakan Convolutional Neural Network". Dengan sistem yang dihasilkan, diharapkan dapat membantu mengatasi permasalahan pada imputasi data dan meningkatkan kualitas data tanda vital pasien unit perawatan intensif.

## **1.2. Tujuan Penelitian**

Adapun tujuan dari penulisan Tugas Akhir ini, yaitu:

- 1.1. Meningkatkan hasil evaluasi imputasi pada data tanda vital dengan menggunakan metode Autoencoder dan CNN untuk melakukan Imputasi Multivariat pada data tersebut.
- 1.2. Merancang model imputasi pada data tanda vital pasien unit perawatan intensif dan menguji model terbaik dari hasil yang telah didapatkan.

### **1.3. Perumusan Masalah**

Adapun masalah yang diangkat pada penelitian ini yaitu track record pada pasien unit perawatan intensif yang banyak nilai yang hilang, membuat para peneliti melakukan penelitian untuk menyelesaikan permasalahan imputasi pada data tanda vital pasien unit perawatan intensif, telah dipilih metode dan pendekatan terbaik yaitu Imputasi Multivariat dengan menggunakan metode Autoencoder dan CNN. Tujuannya adalah untuk memperoleh hasil yang optimal.

### **1.4. Metodologi Penelitian**

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

Metode ini dilakukan dengan cara mencari dan mengumpulkan referensi data berupa literature yang terdapat pada buku, paper dan internet mengenai “Multivariate Imputation”

#### **1.4.2. Metode Konsultasi**

Metode ini dilakukan dengan konsultasi dengan ahli atau pihak yang memiliki pengetahuan dan pengalaman dalam menangani permasalahan yang dihadapi dalam penulisan tugas akhir.

#### **1.4.3. Metode Pembuatan Model**

Metode ini membuat suatu perancangan pemodelan dengan menggunakan simulasi.

#### **1.4.4. Metode Pengujian dan Validasi**

Metode ini melakukan pengujian terhadap metode imputasi yang telah dibuat, apakah metode tersebut dapat menghasilkan nilai yang baik atau tidak.

#### **1.4.5. Metode Hasil dan Analisa**

Hasil dari pengujian pada penelitian ini akan dianalisis kelebihan dan kekurangan dari metode tersebut, sehingga dapat digunakan dan diimprovisasi untuk penelitian selanjutnya.

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

Pada tahap ini, peneliti akan menyimpulkan hasil dari penelitian yang telah dilakukan dan memberikan saran yang dapat dijadikan referensi untuk penelitian selanjutnya.

### **1.5. Sistematika Penulisan**

Adapun sistematika penulisan dalam tugas akhir ini adalah sebagai berikut:

#### **BAB I PENDAHULUAN**

Bagian ini memberikan uraian tentang awal dari suatu penulisan, meliputi latar belakang, perumusan dan batasan masalah, tujuan dan manfaat, metodologi penelitian, serta sistematika penulisan.

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

Bagian ini membicarakan tentang fondasi teori yang digunakan untuk mengatasi permasalahan yang dihadapi dalam penelitian.

#### **BAB III METODOLOGI**

Bagian ini berisi penjelasan detail mengenai teknik, metode, serta alur proses yang digunakan dalam penelitian.

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

Bagian ini berisi analisis hasil pengujian yang mencakup evaluasi terhadap kelebihan dan kekurangan dari penelitian yang telah dilakukan.

#### **BAB V PENUTUP**

Bagian ini berisi tentang ringkasan kesimpulan yang diambil dari hasil penelitian sebelumnya dan rekomendasi untuk perbaikan dan pengembangan penelitian di masa depan.

**DAFTAR PUSTAKA**

Bagian ini berisi daftar referensi dari sumber-sumber informasi yang digunakan dalam metode literatur.

**LAMPIRAN**

Bagian ini mencakup lampiran berupa formulir perbaikan dan juga pemeriksaan tingkat kemiripan karya dengan sumber lain.



## DAFTAR PUSTAKA

- [1] 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.
- [2] 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.
- [3] 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.
- [4] R. C. Pereira, M. S. Santos, P. P. Rodrigues, and P. H. Abreu, “Reviewing autoencoders for missing data imputation: Technical trends, applications and outcomes,” *J. Artif. Intell. Res.*, vol. 69, pp. 1255–1285, 2020, doi: 10.1613/JAIR.1.12312.
- [5] L. A. Menéndez García *et al.*, “A Method of Pruning and Random Replacing of Known Values for Comparing Missing Data Imputation Models for Incomplete Air Quality Time Series,” *Appl. Sci.*, vol. 12, no. 13, p. 6465, 2022, doi: 10.3390/app12136465.
- [6] M. Chen, H. Zhu, Y. Chen, and Y. Wang, “A Novel Missing Data Imputation Approach for Time Series Air Quality Data Based on Logistic Regression,” *Atmosphere (Basel)*, vol. 13, no. 7, 2022, doi: 10.3390/atmos13071044.
- [7] K. K. R. Samal, K. S. Babu, and S. K. Das, “Temporal convolutional denoising autoencoder network for air pollution prediction with missing values,” *Urban Clim.*, vol. 38, no. May, p. 100872, 2021, doi: 10.1016/j.uclim.2021.100872.
- [8] J. C. Kim and K. Chung, “Recurrent Neural Network-Based Multimodal

- Deep Learning for Estimating Missing Values in Healthcare,” *Appl. Sci.*, vol. 12, no. 15, 2022, doi: 10.3390/app12157477.
- [9] M. A. U. Zaman and D. Du, “A Stochastic Multivariate Irregularly Sampled Time Series Imputation Method for Electronic Health Records,” *BioMedInformatics*, vol. 1, no. 3, pp. 166–181, 2021, doi: 10.3390/biomedinformatics1030011.
- [10] Z. Ding, G. Mei, S. Cuomo, Y. Li, and N. Xu, “Comparison of Estimating Missing Values in IoT Time Series Data Using Different Interpolation Algorithms,” *Int. J. Parallel Program.*, vol. 48, no. 3, pp. 534–548, 2020, doi: 10.1007/s10766-018-0595-5.
- [11] Z. Che, S. Purushotham, K. Cho, D. Sontag, and Y. Liu, “Recurrent Neural Networks for Multivariate Time Series with Missing Values,” *Sci. Rep.*, vol. 8, no. 1, pp. 1–13, 2018, doi: 10.1038/s41598-018-24271-9.
- [12] O. T. Abdala and M. Saeed, “Estimation of missing values in clinical laboratory measurements of ICU patients using a weighted K-nearest neighbors algorithm,” *Comput. Cardiol.*, vol. 31, no. October 2004, pp. 693–696, 2004, doi: 10.1109/cic.2004.1443033.
- [13] X. Zhang, C. Yan, C. Gao, B. A. Malin, and Y. Chen, “Predicting Missing Values in Medical Data Via XGBoost Regression,” *J. Healthc. Informatics Res.*, vol. 4, no. 4, pp. 383–394, 2020, doi: 10.1007/s41666-020-00077-1.
- [14] A. F. Costa, M. S. Santos, J. P. Soares, and P. H. Abreu, “Missing data imputation via denoising autoencoders: The untold story,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11191 LNCS, no. November, pp. 87–98, 2018, doi: 10.1007/978-3-030-01768-2\_8.
- [15] L. Gondara and K. Wang, “Recovering loss to followup information using denoising autoencoders,” *Proc. - 2017 IEEE Int. Conf. Big Data, Big Data 2017*, vol. 2018-Janua, pp. 1936–1945, 2017, doi: 10.1109/BigData.2017.8258139.

- [16] A. Sánchez-Morales, J. L. Sancho-Gómez, J. A. Martínez-García, and A. R. Figueiras-Vidal, “Improving deep learning performance with missing values via deletion and compensation,” *Neural Comput. Appl.*, vol. 32, no. 17, pp. 13233–13244, 2020, doi: 10.1007/s00521-019-04013-2.
- [17] Y. L. Qiu, H. Zheng, and O. Gevaert, “Genomic data imputation with variational auto-encoders,” *Gigascience*, vol. 9, no. 8, pp. 1–12, 2020, doi: 10.1093/gigascience/giaa082.
- [18] M. Shen, H. Zhang, Y. Cao, F. Yang, and Y. Wen, “Missing Data Imputation for Solar Yield Prediction using Temporal Multi-Modal Variational Auto-Encoder,” *MM 2021 - Proc. 29th ACM Int. Conf. Multimed.*, pp. 2558–2566, 2021, doi: 10.1145/3474085.3475430.
- [19] B. Shickel, P. J. Tighe, A. Bihorac, and P. Rashidi, “Deep EHR: A Survey of Recent Advances in Deep Learning Techniques for Electronic Health Record (EHR) Analysis,” *IEEE J. Biomed. Heal. Informatics*, vol. 22, no. 5, pp. 1589–1604, 2018, doi: 10.1109/JBHI.2017.2767063.
- [20] M. Chen, H. Zhu, Y. Chen, and Y. Wang, “A Novel Missing Data Imputation Approach for Time Series Air Quality Data Based on Logistic Regression,” 2022.
- [21] A. L. Goldberger *et al.*, “Current Perspective,” 2000.
- [22] A. E. W. Johnson *et al.*, “Data Descriptor : MIMIC-III , a freely accessible critical care database,” pp. 1–9, 2016.
- [23] D. Chang, D. Chang, and M. Pourhomayoun, “Risk prediction of critical vital signs for ICU patients using recurrent neural network,” *Proc. - 6th Annu. Conf. Comput. Sci. Comput. Intell. CSCI 2019*, pp. 1003–1006, 2019, doi: 10.1109/CSCI49370.2019.00191.
- [24] A. Youssef *et al.*, “Vital Signs Prediction and Early Warning Score Calculation Based on Continuous Monitoring of Hospitalised Patients Using Wearable Technology,” 2020, doi: 10.3390/s20226593.
- [25] X. Wang and C. Wang, “Time Series Data Cleaning: A Survey,” *IEEE*

- Access*, vol. 8, pp. 1866–1881, 2020, doi: 10.1109/ACCESS.2019.2962152.
- [26] Y. P. Chen, C. H. Huang, Y. H. Lo, Y. Y. Chen, and F. Lai, “Combining attention with spectrum to handle missing values on time series data without imputation,” *Inf. Sci. (Ny)*, vol. 609, no. August, pp. 1271–1287, 2022, doi: 10.1016/j.ins.2022.07.124.
- [27] R. L. Hale, “Cluster analysis in school psychology: An example,” *J. Sch. Psychol.*, vol. 19, no. 1, pp. 51–56, 1981, doi: 10.1016/0022-4405(81)90007-8.
- [28] D. S. Bouhlila and F. Sellaouti, “Multiple imputation using chained equations for missing data in TIMSS: a case study,” *Large-Scale Assessments Educ.*, vol. 1, no. 1, pp. 1–33, 2013, doi: 10.1186/2196-0739-1-4.
- [29] I. Eldiyana, E. Nurlaelah, and N. Herrhyanto, “Estimasi Missing Data Dengan Metode Multivariate Imputation By Chained Equations (Mice) Untuk Membentuk Persamaan Regresi Linear Berganda,” *J. EurekaMatika*, vol. 8, no. 1, pp. 97–107, 2020.
- [30] L. Cappelletti, T. Fontana, G. W. Di Donato, L. Di Tucci, E. Casiraghi, and G. Valentini, “Complex data imputation by auto-encoders and convolutional neural networks—A case study on genome gap-filling,” *Computers*, vol. 9, no. 2, 2020, doi: 10.3390/computers9020037.
- [31] W. Ren and M. Han, “Variational auto-encoders based on the shift correction for imputation of specific missing in multivariate time series Variational auto-encoders based on the shift correction for imputation of specific missing in multivariate time series,” no. May 2022, 2021, doi: 10.1016/j.measurement.2021.110055.
- [32] C. Lu and Y. Mei, “An imputation method for missing data based on an extreme learning machine auto-encoder,” *IEEE Access*, vol. PP, no. c, p. 1, 2018, doi: 10.1109/ACCESS.2018.2868729.
- [33] Q. Zhang and C. Shu, “Performance Investigation of Learning Rate Decay

- in LMS-Based Equalization,” *IEEE Photonics Technol. Lett.*, vol. 33, no. 2, pp. 109–112, 2021, doi: 10.1109/LPT.2020.3045749.
- [34] E. F. Galutira, “A Novel Learning Rate Decay Function of Kohonen Self-Organizing Maps Using the Exponential Decay Average Rate of Change for Image Clustering,” pp. 55–59, 2018.
- [35] Y. H. Ling and J. Scarlett, “Optimal Rates of Teaching and Learning under Uncertainty,” *IEEE Trans. Inf. Theory*, vol. 67, no. 11, pp. 7067–7080, 2021, doi: 10.1109/TIT.2021.3107733.
- [36] S. V. Georgakopoulos and V. P. Plagianakos, “Efficient Learning Rate Adaptation for Convolutional Neural Network Training,” *Proc. Int. Jt. Conf. Neural Networks*, vol. 2019-July, 2019, doi: 10.1109/IJCNN.2019.8852033.
- [37] J. Konar, P. Khandelwal, and R. Tripathi, “Comparison of Various Learning Rate Scheduling Techniques on Convolutional Neural Network,” *2020 IEEE Int. Students’ Conf. Electr. Electron. Comput. Sci. SCEECS 2020*, 2020, doi: 10.1109/SCEECS48394.2020.94.