

**PENERAPAN *DEEP LEARNING* PADA IMPUTASI DATA  
TANDA VITAL UNTUK MENINGKATKAN AKURASI  
PREDIKSI HENTI JANTUNG PADA PASIEN UNIT  
PERAWATAN INTENSIF**

**TUGAS AKHIR**

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



**OLEH :**

**THESA JIORNIA**

**09011281823031**

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

**2022**

**HALAMAN PENGESAHAN**

**PENERAPAN *DEEP LEARNING* PADA IMPUTASI DATA TANDA  
VITAL UNTUK MENINGKATKAN AKURASI PREDIKSI HENTI  
JANTUNG PADA PASIEN UNIT PERAWATAN INTENSIF**

**TUGAS AKHIR**


Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Sistem Komputer

**OLEH :**

**THESA JIORNIA  
09011281823031**

Indralaya, 2022  
Mengetahui,

Pembimbing Tugas Akhir

  
**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 : Jum'at

Tanggal : 15 Juli 2022

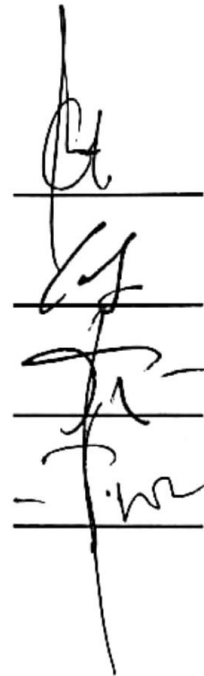
**Tim Penguji :**

1. Ketua : Sutarno, S.T., M.T.

2. Sekretaris : Iman Saladin B. Azhar, M.MSI

3. Penguji : Prof. Dr. Ir. Siti Nurmaini, M.T.

4. Pendamping : Firdaus, S.T., M.Kom.



Mengetahui,

Ketua Jurusan Sistem Komputer



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

**NIP. 196612032006041001**

## HALAMAN PERNYATAAN

**Yang bertanda tangan dibawah ini:**

**Nama : Thesa Jiornmia**  
**NIM : 09011281823031**  
**Judul : Penerapan *Deep Learning* pada Imputasi Data Tanda Vital  
untuk Meningkatkan Akurasi Prediksi Henti Jantung pada  
Pasien Unit Perawatan Intensif**

**Hasil Pengecekan Software *iThenticate/Turnitin* : 6%**

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 tidak dipaksakan.



**Indralaya, Agustus 2022**



**Thesa Jiornmia**

**09011281823031**

## 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 “Penerapan *Deep Learning* pada Imputasi Data Tanda Vital untuk Meningkatkan Akurasi Prediksi Henti Jantung pada Pasien Unit Perawatan Intensif”.

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 Rossi Passarella, S.T., M.Eng. selaku Dosen Pembimbing Akademik di Jurusan Sistem Komputer Universitas Sriwijaya.
5. Bapak Firdaus, S.T., M.Kom. 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.
6. 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.
7. Mbak Ade Iriani Safitri, Kak Naufal Rachmatullah, dan Mbak Annisa Darmawahyuni.
8. Rekan seperjuangan di group ISysRG yang selalu membantu dalam pengerjaan Tugas Akhir ini.
9. Mbak Renny selaku Administrasi Jurusan Sistem Komputer yang telah membantu dalam proses administrasi terkait Tugas Akhir.
10. Kakak tingkat dan teman-teman Sistem Komputer angkatan 2018 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.

Indralaya, Agustus 2022

Penulis



**Thesa Jionmia**

09011281823031

# DAFTAR ISI

	<b>Halaman</b>
<b>HALAMAN PENGESAHAN</b> .....	ii
<b>HALAMAN PERSETUJUAN</b> .....	iii
<b>HALAMAN PERNYATAAN</b> .....	iv
<b>KATA PENGANTAR</b> .....	v
<b>DAFTAR ISI</b> .....	vii
<b>DAFTAR GAMBAR</b> .....	x
<b>DAFTAR TABEL</b> .....	xi
<b>ABSTRAK</b> .....	xiii
<b>BAB I PENDAHULUAN</b> .....	1
1.1. Latar Belakang .....	1
1.2. Tujuan dan Manfaat.....	3
1.2.1. Tujuan.....	3
1.2.2. Manfaat.....	3
1.3. Perumusan dan Batasan Masalah .....	3
1.3.1. Perumusan Masalah.....	3
1.3.2. Batasan Masalah .....	4
1.4. Metodologi Penelitian .....	4
1.4.1. Metode Studi Pustaka dan Literatur .....	4
1.4.2. Metode Konsultasi.....	4
1.4.3. Metode Pembuatan Model.....	4
1.4.4. Metode Pengujian dan Validasi.....	4
1.4.5. Metode Hasil dan Analisa.....	5
1.4.6. Metode Penarikan Kesimpulan dan Saran.....	5
1.5. Sistematika Penulisan.....	5
<b>BAB II TINJAUAN PUSTAKA</b> .....	6
2.1. Henti Jantung.....	6
2.2. <i>Medical Information Mart for Intensive Care III</i> .....	6
2.3. Tanda Vital.....	6

2.4. Imputasi Data .....	7
2.5. <i>Deep Learning</i> .....	7
2.6. <i>Convolutional Neural Network</i> .....	8
2.6.1. <i>Convolutional Layer</i> .....	8
2.6.2. <i>Fully Connected Layer</i> .....	9
2.7. Evaluasi Model.....	9
2.7.1. <i>Mean Squared Error</i> .....	9
2.7.2. <i>Root Mean Squared Error</i> .....	9
<b>BAB III METODOLOGI PENELITIAN</b> .....	10
3.1. Pendahuluan .....	10
3.2. Kerangka Kerja.....	10
3.3. Akuisisi Data .....	11
3.4. Pra-Pengolahan Data .....	13
3.4.1. Menghilangkan Nilai NaN.....	14
3.4.2. Normalisasi Data .....	14
3.4.3. Membuat dan Menentukan Letak Nilai NaN <i>Artificial</i> .....	15
3.4.4. Label Nilai NaN <i>Artificial</i> .....	15
3.4.5. <i>Mask Layer</i> .....	16
3.5. Pembagian Data.....	17
3.6. Imputasi Data .....	17
3.7. Evaluasi Kinerja Model.....	19
<b>BAB IV HASIL DAN PEMBAHASAN</b> .....	20
4.1. Pendahuluan .....	20
4.2. Database MIMIC-III.....	20
4.3. Hasil Akuisisi Data.....	21
4.4. Hasil Pra-Pengolahan Data.....	22
4.5. Hasil Imputasi Data .....	23
4.5.1. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 3.....	23
4.5.2. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 4.....	24
4.5.3. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 5.....	25



4.5.4. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 6.....	26
4.5.5. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 7.....	27
4.5.6. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 8.....	28
4.5.7. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 9.....	29
4.5.8. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 10.....	30
4.5.9. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 15.....	31
4.5.10. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 20.....	32
4.5.11. Hasil Imputasi Data dengan 3 Layer Konvolusi dan <i>Window length</i> 30.....	33
4.5.12. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 3.....	34
4.5.13. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 4.....	35
4.5.14. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 5.....	36
4.5.15. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 6.....	37
4.5.16. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 7.....	38
4.5.17. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 8.....	39
4.5.18. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 9.....	40
4.5.19. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 10.....	41
4.5.20. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 15.....	42
4.5.21. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 20.....	43
4.5.22. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 30.....	44
4.5.23. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 40.....	45
4.5.24. Hasil Imputasi Data dengan 4 Layer Konvolusi dan <i>Window length</i> 50.....	46
4.6. Analisa.....	46
4.7. Plot Hasil Data Imputasi dan Aktual Data .....	51
<b>BAB V KESIMPULAN.....</b>	<b>53</b>
5.1. Kesimpulan.....	53
5.2. Saran.....	53
<b>DAFTAR PUSTAKA .....</b>	<b>54</b>
<b>LAMPIRAN.....</b>	<b>57</b>

## DAFTAR GAMBAR

	<b>Halaman</b>
<b>Gambar 2.1</b> Arsitektur CNN.....	8
<b>Gambar 3.1</b> Metode Penelitian .....	11
<b>Gambar 3.2</b> Tabel chartevents MIMIC-III .....	12
<b>Gambar 3.3</b> Sampe data tanda vital pasien ICU .....	13
<b>Gambar 3.4</b> Pra-pengolahan data.....	13
<b>Gambar 3.5</b> Sample data setelah nilai NaN dihilangkan .....	14
<b>Gambar 3.6</b> Normalisasi data menggunakan MinMax scaler pada range 0-1 .....	14
<b>Gambar 3.7</b> Contoh posisi nilai NaN pada data .....	15
<b>Gambar 3.8</b> Nilai NaN diisi dengan metode median dan diberi label .....	16
<b>Gambar 3.9</b> Contoh mask layer .....	16
<b>Gambar 3.10</b> Arsitektur CNN.....	18
<b>Gambar 4.1</b> Plotting data imputasi dan aktual data 3 layer konvolusi CNN.....	52
<b>Gambar 4.2</b> Plotting data imputasi dan aktual data 4 layer konvolusi CNN.....	52

## DAFTAR TABEL

	<b>Halaman</b>
<b>Tabel 3.1</b> Pembagian data latih dan data uji.....	17
<b>Tabel 3.2</b> Hyperparameter model pada arsitektur CNN.....	18
<b>Tabel 4.1</b> Tabel pada database MIMIC-III.....	20
<b>Tabel 4.2</b> Nilai untuk menentukan tanda vital dari data chartevents MIMIC-III.....	21
<b>Tabel 4.3</b> Total data pada setiap kolom dataset tanda vital pasien ICU.....	22
<b>Tabel 4.4</b> Nilai min dan max tanda vital setelah menghilangkan nilai NaN.....	22
<b>Tabel 4.5</b> RMSE data uji dengan 3 layer konvolusi dan window length 3 .....	23
<b>Tabel 4.6</b> RMSE data unseen model 3 layer konvolui dan window length 3 .....	24
<b>Tabel 4.7</b> RMSE data uji dengan 3 layer konvolusi dan window length 4 .....	24
<b>Tabel 4.8</b> RMSE data unseen model 3 layer konvolui dan window length 4 .....	25
<b>Tabel 4.9</b> RMSE data uji dengan 3 layer konvolusi dan window length 5 .....	25
<b>Tabel 4.10</b> RMSE data unseen model 3 layer konvolui dan window length 5 .....	26
<b>Tabel 4.11</b> RMSE data uji dengan 3 layer konvolusi dan window length 6 .....	26
<b>Tabel 4.12</b> RMSE data unseen model 3 layer konvolui dan window length 6 .....	27
<b>Tabel 4.13</b> RMSE data uji dengan 3 layer konvolusi dan window length 7 .....	27
<b>Tabel 4.14</b> RMSE data unseen model 3 layer konvolui dan window length 7 .....	28
<b>Tabel 4.15</b> RMSE data uji dengan 3 layer konvolusi dan window length 8 .....	28
<b>Tabel 4.16</b> RMSE data unseen model 3 layer konvolui dan window length 8 .....	29
<b>Tabel 4.17</b> RMSE data uji dengan 3 layer konvolusi dan window length 9 .....	29
<b>Tabel 4.18</b> RMSE data unseen model 3 layer konvolui dan window length 9 .....	30
<b>Tabel 4.19</b> RMSE data uji dengan 3 layer konvolusi dan window length 10 .....	30
<b>Tabel 4.20</b> RMSE data unseen model 3 layer konvolui dan window length 10 .....	31
<b>Tabel 4.21</b> RMSE data uji dengan 3 layer konvolusi dan window length 15 .....	31
<b>Tabel 4.22</b> RMSE data unseen model 3 layer konvolui dan window length 15 .....	32
<b>Tabel 4.23</b> RMSE data uji dengan 3 layer konvolusi dan window length 20 .....	32
<b>Tabel 4.24</b> RMSE data unseen model 3 layer konvolui dan window length 20 .....	33
<b>Tabel 4.25</b> RMSE data uji dengan 3 layer konvolusi dan window length 30 .....	33
<b>Tabel 4.26</b> RMSE data unseen model 3 layer konvolui dan window length 30 .....	34
<b>Tabel 4.27</b> RMSE data uji dengan 4 layer konvolusi dan window length 3 .....	34
<b>Tabel 4.28</b> RMSE data unseen model 4 layer konvolui dan window length 3 .....	35

<b>Tabel 4.29</b>	RMSE data uji dengan 4 layer konvolusi dan window length 4 .....	35
<b>Tabel 4.30</b>	RMSE data unseen model 4 layer konvolui dan window length 4 .....	36
<b>Tabel 4.31</b>	RMSE data uji dengan 4 layer konvolusi dan window length 5 .....	36
<b>Tabel 4.32</b>	RMSE data unseen model 4 layer konvolui dan window length 5 .....	37
<b>Tabel 4.33</b>	RMSE data uji dengan 4 layer konvolusi dan window length 6 .....	37
<b>Tabel 4.34</b>	RMSE data unseen model 4 layer konvolui dan window length 6 .....	38
<b>Tabel 4.35</b>	RMSE data uji dengan 4 layer konvolusi dan window length 7 .....	38
<b>Tabel 4.36</b>	RMSE data unseen model 4 layer konvolui dan window length 7 .....	39
<b>Tabel 4.37</b>	RMSE data uji dengan 4 layer konvolusi dan window length 8 .....	39
<b>Tabel 4.38</b>	RMSE data unseen model 4 layer konvolui dan window length 8 .....	40
<b>Tabel 4.39</b>	RMSE data uji dengan 4 layer konvolusi dan window length 9 .....	40
<b>Tabel 4.40</b>	RMSE data unseen model 4 layer konvolui dan window length 9 .....	41
<b>Tabel 4.41</b>	RMSE data uji dengan 4 layer konvolusi dan window length 10 .....	41
<b>Tabel 4.42</b>	RMSE data unseen model 4 layer konvolui dan window length 10 .....	42
<b>Tabel 4.43</b>	RMSE data uji dengan 4 layer konvolusi dan window length 15 .....	42
<b>Tabel 4.44</b>	RMSE data unseen model 4 layer konvolui dan window length 15 .....	43
<b>Tabel 4.45</b>	RMSE data uji dengan 4 layer konvolusi dan window length 20 .....	43
<b>Tabel 4.46</b>	RMSE data unseen model 4 layer konvolui dan window length 20 .....	44
<b>Tabel 4.47</b>	RMSE data uji dengan 4 layer konvolusi dan window length 30 .....	44
<b>Tabel 4.48</b>	RMSE data unseen model 4 layer konvolui dan window length 30 .....	45
<b>Tabel 4.49</b>	RMSE data uji dengan 4 layer konvolusi dan window length 40 .....	45
<b>Tabel 4.50</b>	RMSE data unseen model 4 layer konvolui dan window length 40 .....	45
<b>Tabel 4.51</b>	RMSE data uji dengan 4 layer konvolusi dan window length 50 .....	46
<b>Tabel 4.52</b>	RMSE data unseen model 4 layer konvolui dan window length 50 .....	46
<b>Tabel 4.53</b>	Perbandingan hasil kinerja model 3 layer konvolusi CNN .....	47
<b>Tabel 4.54</b>	Perbandingan hasil kinerja model 4 layer konvolusi CNN .....	49

# **APPLICATION OF DEEP LEARNING ON VITAL SIGN DATA IMPUTATION TO IMPROVE THE ACCURACY OF CARDIAC ARREST PREDICTION IN INTENSIVE CARE UNIT PATIENTS**

**THESA JIORNIA (09011281823031)**

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

Email: [thesa.04.tj@gmail.com](mailto:thesa.04.tj@gmail.com)

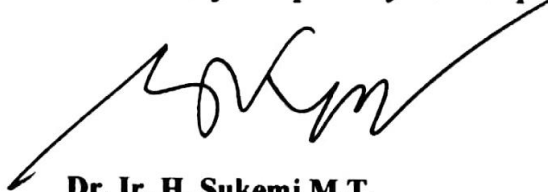
## **ABSTRACT**

*Cardiac arrest refers to a sudden interruption of cardiac activity that commonly caused by certain anomalous events. The patients of cardiac arrest have at least one abnormal vital sign in the one to four hours prior to the onset of cardiac arrest. In the previous studies, the patient's vital sign data have used many missing values. Due to the large number of missing values in the data, to process the data is so challenging. It is necessary to perform data imputation, in order to fill in the missing values in the patient's vital sign data. Machine learning for data imputation has been often implemented, but the result tends to get the poor performance with the datasets that have high missing values. Thus, deep learning methods are used, because they are proven to have the ability to explore and capture information hidden in data which makes progress in data imputation. This research proposes the Convolutional Neural Network using three convolution layers and four convolution layers. The Convolutional Neural Network with three convolutional layers produces 88 models with the smallest RMSE result of 0.06378 and the Convolutional Neural Network with four convolutional layers produces 95 models with the smallest RMSE result of 0.062431.*

**Keywords:** *Cardiac arrest, data imputation, missing value, convolutional neural network*

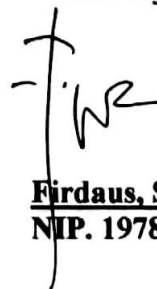
### **Acknowledged By,**

***The Head of Computer Systems Department***



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

***Final Project Advisor***



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

**PENERAPAN *DEEP LEARNING* PADA IMPUTASI DATA  
TANDA VITAL UNTUK MENINGKATKAN AKURASI  
PREDIKSI HENTI JANTUNG PADA PASIEN UNIT  
PERAWATAN INTENSIF**

**THESA JIORNIA (09011281823031)**

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya  
Email: [thesa.04.tj@gmail.com](mailto:thesa.04.tj@gmail.com)

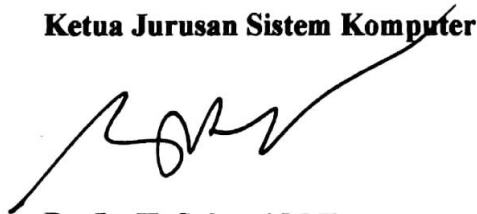
**ABSTRAK**

Henti jantung mengacu pada gangguan mendadak aktivitas jantung, biasanya disebabkan oleh beberapa kejadian anomali tertentu. Pada pasien yang terkena henti jantung, setidaknya memiliki satu tanda vital abnormal dalam 1-4 jam sebelum terjadinya henti jantung. Pada penelitian yang melakukan prediksi henti jantung, data tanda vital pasien yang digunakan terdapat banyak nilai yang hilang. Karena banyaknya nilai yang hilang pada data tersebut, membuat lebih sulit dalam melakukan pengolahan data. Sehingga, diperlukan melakukan imputasi data, agar dapat mengisi nilai yang hilang pada data tanda vital pasien tersebut. *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. Penelitian ini menggunakan metode Convolutional Neural Network dengan menggunakan tiga layer konvolusi dan empat layer konvolusi. Pada Convolutional Neural Network dengan tiga layer konvolusi menghasilkan 88 model dengan hasil RMSE paling kecil 0,06378 dan Convolutional Neural Network dengan empat layer konvolusi menghasilkan 95 model dengan hasil RMSE paling kecil 0,062431.

**Kata Kunci:** Henti jantung, imputasi data, nilai yang hilang, convolutional neural network

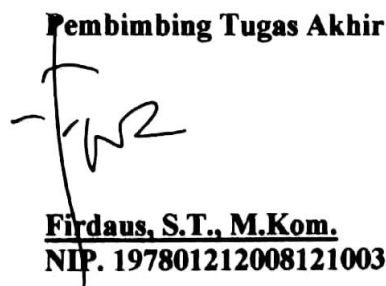
**Mengetahui,**

**Ketua Jurusan Sistem Komputer**



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

**Pembimbing Tugas Akhir**



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

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang**

Henti jantung merupakan peristiwa kematian yang paling serius pada pasien di unit perawatan intensif (ICU) [1]-[4], tetapi tidak mudah diprediksi karena karakteristik data yang kompleks dan tergantung waktu dari pasien gawat darurat [4]. Tingkat kelangsungan hidup dari pasien henti jantung yang rendah [1]-[3], mengakibatkan miliaran korban per-tahun [5]. Mengingat pentingnya masalah ini, beberapa penelitian telah dilakukan untuk memprediksi henti jantung pada pasien sehingga dapat mengurangi angka kematian pada pasien henti jantung dan meningkatkan persentase dari kelangsungan hidup pasien. Pada penelitian [1], [6], menunjukkan bahwa, pada pasien yang terkena henti jantung setidaknya memiliki satu tanda vital abnormal dalam 1-4 jam sebelum terjadinya henti jantung [6]. Pemantauan tanda vital samping tempat tidur merupakan penilaian medis yang paling umum. Ini dapat membantu mengidentifikasi kondisi kesehatan dari pasien. Karena telah banyak digunakan dalam praktik klinis, data tanda vital pasien cocok untuk digunakan sebagai sumber data untuk prediksi henti jantung [1].

Pemantauan tanda vital yang terletak di samping tempat tidur pasien [1], merupakan penilaian medis yang paling umum untuk melihat serta mendokumentasikan adanya kemajuan atau penurunan kesehatan pada pasien [7]. Sampai saat ini, pemantauan tanda-tanda vital dilakukan oleh perawat yang pergi ke tempat tidur pasien pada interval waktu tertentu untuk mengumpulkan data klinis dan fisiologis lalu membuat penilaian dari kondisi pasien. Pasien mungkin mengalami penurunan kondisi kesehatan diantara jeda interval pemantauan dan staf tenaga medis rentan terhadap keterlambatan atau kelalaian pengambilan data penting selama periode sibuk atau saat staf yang tersedia lebih sedikit seperti akhir pekan dan malam hari [4]. Kegagalan dalam penyelamatan pasien, seperti celah dari penyedia layanan kesehatan atau tenaga medis yang menempatkan pasien pada risiko bahaya, setelah menunjukkan bahwa mengenali tanda-tanda peringatan dini dari perburukan klinis dan fisiologis pasien dapat mencegah atau mengurangi bahaya akibat efek samping yang serius [7].

Pada penelitian [8] yang melakukan prediksi henti jantung, dataset tanda vital pasien yang digunakan banyak terdapat nilai yang hilang atau *Not a Number* (NaN) pada hampir setiap data tanda vital pasien [8]-[9]. Karena banyaknya nilai NaN pada data tersebut, membuat lebih sulit dalam mengolah data agar dapat dimasukkan ke dalam model yang dirancang dan membuat hasil evaluasi pada model tersebut mencapai hasil yang diinginkan [10]-[11]. Sehingga, diperlukan melakukan imputasi data agar dapat mengisi nilai NaN [11] pada data tanda vital pasien ICU tersebut. Untuk mengisi nilai NaN tersebut, digunakan berbagai metode, seperti nilai NaN tersebut diisi dengan nilai yang sebelumnya atau jika tidak ada nilai sebelumnya, maka akan diisi 0.

Banyak metode telah diusulkan untuk meminimalkan data yang hilang dan dapat dibagi menjadi dua kategori: Satu, dengan mencoba memodelkan proses data yang hilang dan menggunakan semua data yang tersedia untuk memperkirakan parameter model secara langsung dan dua, dengan mencoba untuk mengisi/imputasi nilai yang hilang dengan nilai prediksi yang masuk akal. Metode imputasi lebih disukai karena keuntungannya yang jelas, yaitu, menyediakan pengguna dengan kumpulan data lengkap yang dapat dianalisis menggunakan model yang ditentukan pengguna [11].

Teknik *machine learning* untuk imputasi data, di luar metode *deep learning*, telah sering diterapkan. Teknik ini cenderung menghasilkan hasil yang baik ketika dataset memiliki jumlah kecil nilai yang hilang tetapi berkinerja buruk dengan dataset yang memiliki nilai hilang yang tinggi. Juga, hubungan temporal antara pengamatan, dan informasi penting dari nilai-nilai yang hilang dan *pattern* data tidak cukup ditangkap oleh teknik ini [12]. *Deep learning* [12]-[14] menyediakan strategi imputasi data yang lebih canggih untuk data *time series* multivariat, dengan mempertimbangkan korelasi temporal dalam setiap *time series* serta memanfaatkan korelasi lintas variabel [12].

Metode *deep learning* telah membuat kemajuan dalam imputasi, karena terbukti memiliki kemampuan untuk menggali dan menangkap data informasi yang tersembunyi dalam data. Karakteristik ini dapat memungkinkan untuk menghubungkan nilai NaN dengan model tersebut. Metode *deep learning* telah diterapkan pada imputasi multivariabel dan menunjukkan kemajuan positif dalam mengisi nilai NaN. Contoh metode *deep learning* yang digunakan untuk imputasi data yaitu *Recurrent Neural Networks* [12]-[14]. Tidak hanya RNN yang digunakan, melainkan juga menggabungkan model seperti *Gated Recurrent Unit*, *Generative Adversarial*



*Networks, Bidirectional Recurrent Networks* [15] dan *Convolutional Neural Network* [16].

Pada tugas akhir ini penulis akan membuat sistem untuk melakukan imputasi data untuk meningkatkan hasil prediksi henti jantung pada pasien berdasarkan tanda vital yang ditunjukkan pada alat samping tempat tidur pasien di rumah sakit. Hal ini dapat membantu para medis untuk cepat tanggap dalam melakukan pertolongan pada pasien dan mengurangi tingkat kematian yang terjadi pada pasien. Adapun judul dari tugas akhir ini, yaitu “Penerapan *Deep Learning* pada Imputasi Data Tanda Vital untuk Meningkatkan Akurasi Prediksi Henti Jantung pada Pasien Unit Perawatan Intensif”.

## **1.2. Tujuan dan Manfaat**

### **1.2.1. Tujuan**

Adapun tujuan dari penulisan Tugas Akhir ini, yaitu:

1. Dapat melakukan imputasi pada data tanda vital untuk meningkatkan hasil prediksi henti jantung pasien unit perawatan intensif dengan menggunakan metode *Deep Learning*.
2. Dapat melakukan penentuan metode dan pendekatan terbaik untuk penyelesaian permasalahan pada imputasi data tanda vital pasien ICU.

### **1.2.2. Manfaat**

Adapun manfaat dari penulisan Tugas Akhir ini, yaitu :

1. Membantu dalam pemecahan permasalahan henti jantung, khususnya dalam imputasi nilai NaN pada tanda vital pasien unit perawatan intensif dengan metode *Deep Learning*.
2. Dapat dijadikan sebagai bahan referensi pada penelitian selanjutnya tentang imputasi data tanda vital pasien unit perawatan intensif yang dapat ditingkatkan lebih lanjut.

## **1.3. Perumusan dan Batasan Masalah**

### **1.3.1. Perumusan Masalah**

Bagaimana memilih metode serta pendekatan terbaik dalam merampungkan permasalahan imputasi data tanda vital untuk meningkatkan prediksi henti jantung pada

pasien unit perawatan intensif dengan menggunakan metode *Deep Learning* untuk mendapatkan hasil yang terbaik.

### **1.3.2. Batasan Masalah**

Adapun batasan masalah dari penulisan Tugas Akhir ini, yaitu :

1. Cakupan dari penelitian hanya pada imputasi data tanda vital pada pasien unit perawatan intensif menggunakan *Deep Learning*.
2. Bahasa pemrograman yang digunakan untuk penelitian adalah *Python*.
3. Dataset yang digunakan pada penelitian ini menggunakan dataset tanda vital pasien ICU dari database *Medical Information Mart for Intensive Care III / MIMIC-III*.
4. Record tanda vital pasien ICU yang digunakan hanya yang memiliki nilai (tidak NaN/kosong).
5. Penelitian menggunakan metode *Deep Learning*.

## **1.4. Metodologi Penelitian**

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

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

### **1.4.2. 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.

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

Metode ini membuat suatu perancangan pemodelan dengan menggunakan simulasi.

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

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

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

Hasil dari pengujian pada tugas akhir ini akan dianalisis kekurangannya, sehingga dapat digunakan untuk penelitian selanjutnya.

#### **1.4.6. 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 dilakukan.

### **1.5. Sistematika Penulisan**

Adapun sistematika penulisan dalam tugas akhir ini adalah sebagai berikut :

#### **BAB I PENDAHULUAN**

Pada bagian ini membahas mengenai latar belakang, perumusan dan batasan masalah, tujuan dan manfaat, metodologi penelitian, dan sistematika penulisan.

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

Pada bagian ini membahas mengenai dasar teori yang digunakan untuk memecahkan masalah yang ada pada penelitian.

#### **BAB III METODOLOGI**

Pada bagian ini menjelaskan secara rinci tentang metode, teknik, dan alur proses yang dilakukan pada penelitian.

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

Pada bagian ini membahas mengenai hasil dari pengujian yang telah dicapai meliputi kelebihan dan kekurangan dari penelitian yang telah dilakukan.

#### **BAB V PENUTUP**

Pada bagian ini menjelaskan mengenai kesimpulan dari hasil yang didapatkan dari bab sebelumnya beserta saran demi perbaikan pelaksanaan maupun penyusunan untuk penelitian yang akan datang.

#### **DAFTAR PUSTAKA**

Pada bagian ini memuat sumber-sumber informasi dari metode literatur.

#### **LAMPIRAN**

Pada bagian ini, berisi lampiran form perbaikan dan cek plagiat.

## DAFTAR PUSTAKA

- [1] L. Yijing *et al.*, “Prediction of cardiac arrest in critically ill patients based on bedside vital signs monitoring,” *Comput. Methods Programs Biomed.*, vol. 214, p. 106568, 2022, doi: 10.1016/j.cmpb.2021.106568.
- [2] S. Layeghian Javan, M. M. Sepehri, M. Layeghian Javan, and T. Khatibi, “An intelligent warning model for early prediction of cardiac arrest in sepsis patients,” *Comput. Methods Programs Biomed.*, vol. 178, pp. 47–58, 2019, doi: 10.1016/j.cmpb.2019.06.010.
- [3] S. Baral, A. Alsadoon, P. W. C. Prasad, S. Al Aloussi, and O. H. Alsadoon, “A novel solution of using deep learning for early prediction cardiac arrest in Sepsis patient: enhanced bidirectional long short-term memory (LSTM),” *Multimed. Tools Appl.*, vol. 80, no. 21–23, pp. 32639–32664, 2021, doi: 10.1007/s11042-021-11176-5.
- [4] J. Kim, Y. R. Park, J. H. Lee, J. Lee, Y. Kim, and J. W. Huh, “Development of a Real-Time Risk Prediction Model for In-Hospital Cardiac Arrest in Critically Ill Patients Using Deep Learning: Retrospective Study,” *JMIR Med. Informatics*, vol. 8, no. 3, p. e16349, Mar. 2020, doi: 10.2196/16349.
- [5] R. Shashikant and P. Chetankumar, “Predictive model of cardiac arrest in smokers using machine learning technique based on Heart Rate Variability parameter,” *Appl. Comput. Informatics*, 2019, doi: 10.1016/j.aci.2019.06.002.
- [6] L. W. Andersen *et al.*, “The prevalence and significance of abnormal vital signs prior to in-hospital cardiac arrest,” *Resuscitation*, vol. 98, pp. 112–117, 2016, doi: 10.1016/j.resuscitation.2015.08.016.
- [7] 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.
- [8] S. Hong, S. Lee, J. Lee, W. C. Cha, and K. Kim, “Prediction of cardiac arrest in the emergency department based on machine learning and sequential characteristics: Model development and retrospective clinical validation study,” *JMIR Med. Informatics*, vol. 8, no. 8, pp. 1–14, 2020, doi: 10.2196/15932.
- [9] D. M. Maslove, J. A. Dubin, A. Shrivats, and J. Lee, “Errors, Omissions, and

- Outliers in Hourly Vital Signs Measurements in Intensive Care,” *Crit. Care Med.*, vol. 44, no. 11, pp. e1021–e1030, 2016, doi: 10.1097/CCM.0000000000001862.
- [10] W. Lee, J. Lee, and Y. Kim, “Contextual Imputation with Missing Sequence of EEG Signals Using Generative Adversarial Networks,” *IEEE Access*, vol. 9, pp. 151753–151765, 2021, doi: 10.1109/ACCESS.2021.3126345.
- [11] L. Gondara and K. Wang, “MIDA: Multiple imputation using denoising autoencoders,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10939 LNAI, pp. 260–272, 2018, doi: 10.1007/978-3-319-93040-4\_21.
- [12] P. B. Weerakody, K. W. Wong, G. Wang, and W. Ela, “A review of irregular time series data handling with gated recurrent neural networks,” *Neurocomputing*, vol. 441, pp. 161–178, 2021, doi: 10.1016/j.neucom.2021.02.046.
- [13] 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. 1–12, 2018, doi: 10.1038/s41598-018-24271-9.
- [14] J. Yoon, W. R. Zame, and M. Van Der Schaar, “Multi-directional Recurrent Neural Networks : A Novel Method for Estimating Missing Data,” *ICML Work.*, 2017.
- [15] C. Fang and C. Wang, “Time Series Data Imputation: A Survey on Deep Learning Approaches,” 2020, [Online]. Available: <http://arxiv.org/abs/2011.11347>.
- [16] H. Khan, X. Wang, and H. Liu, “Handling missing data through deep convolutional neural network,” *Inf. Sci. (Ny).*, vol. 595, pp. 278–293, 2022, doi: 10.1016/j.ins.2022.02.051.
- [17] F. Li, H. Xin, J. Zhang, M. Fu, J. Zhou, and Z. Lian, “Prediction model of in-hospital mortality in intensive care unit patients with heart failure: Machine learning-based, retrospective analysis of the MIMIC-III database,” *BMJ Open*, vol. 11, no. 7, pp. 1–17, 2021, doi: 10.1136/bmjopen-2020-044779.
- [18] T. N. Pattalung and S. Chaichulee, “Comparison of machine learning algorithms for mortality prediction in intensive care patients on multi-center critical care

- databases,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1163, no. 1, p. 012027, 2021, doi: 10.1088/1757-899x/1163/1/012027.
- [19] M. Saad, “Deep Learning Based Approaches for Imputation of Time Series Models by,” 2020.
- [20] A. Mohammed and R. Kora, “An effective ensemble deep learning framework for text classification,” *J. King Saud Univ. - Comput. Inf. Sci.*, no. xxxx, 2021, doi: 10.1016/j.jksuci.2021.11.001.
- [21] W. J. Zhang, G. Yang, Y. Lin, C. Ji, and M. M. Gupta, “On Definition of Deep Learning,” *World Autom. Congr. Proc.*, vol. 2018-June, pp. 232–236, 2018, doi: 10.23919/WAC.2018.8430387.
- [22] 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.
- [23] J. Yoon, J. Jordon, and M. Van Der Schaar, “GAIN: Missing data imputation using generative adversarial nets,” *35th Int. Conf. Mach. Learn. ICML 2018*, vol. 13, pp. 9042–9051, 2018.
- [24] J. Patterson and A. Gibson, *Deep Learning: A Practitioner’s Approach*. 2017.
- [25] J. G. Lee *et al.*, “Deep learning in medical imaging: General overview,” *Korean J. Radiol.*, vol. 18, no. 4, pp. 570–584, 2017, doi: 10.3348/kjr.2017.18.4.570.