

**PREDIKSI POLA HENTI JANTUNG BERDASARKAN  
DELAPAN DATA TANDA VITAL MENGGUNAKAN  
METODE *RECURRENT NEURAL NETWORK***

**SKRIPSI**

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



**OLEH :**

**SALWA AYU RAFIKA**

**09011181924012**

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

**2023**

**LEMBAR PENGESAHAN**

**PREDIKSI POLA HENTI JANTUNG BERDASARKAN  
DELAPAN DATA TANDA VITAL MENGGUNAKAN  
METODE *RECURRENT NEURAL NETWORK***

**SKRIPSI**

Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sistem Komputer

Oleh :


**SALWA AYU RAFIKA**

**09011181924012**

Palembang, <sup>27</sup>Juni 2023

Mengetahui,

Ketua Jurusan Sistem Komputer,



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

Pembimbing Tugas Akhir,

A handwritten signature in black ink, appearing to read 'firdaus'.

**Dr. Hirdaus, M.Kom.**  
NIP. 197801212008121003

## HALAMAN PERSETUJUAN

Telah diuji dan lulus pada :

Hari : Kamis

Tanggal : 13 April 2023


Tim Penguji :

1. Ketua : Dr. Bambang Tutuko, M.T.

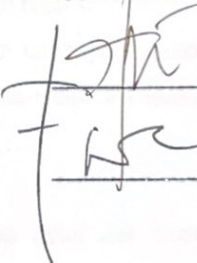
2. Sekrctaris : Muhammad Ali Buchari, S.Kom, M.T.

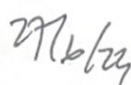
3. Penguji : Prof. Ir. Siti Nurmaini, M.T., Ph.D.

4. Pembimbing : Dr. Firdaus, M.Kom.

 26/6/2023





Mengetahui, 

Ketua Jurusan Sistem Komputer



  
Dr. Ir. Sukemi, M.T.

NIP. 196612032006041001

## HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Salwa Ayu Rafika  
NIM : 09011181924012  
Judul : Prediksi Pola Henti Jantung Berdasarkan Delapan Data Tanda Vital  
Menggunakan Metode *Recurrent Neural Network*

Hasil Pengecekan Software Turnitin : 5%

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, 27 Juni 2023



**Salwa Ayu Rafika**

**NIM. 09011181924012**

## KATA PENGANTAR

Alhamdulillah rabbil ‘alamiin. Segala puji dan syukur penulis panjatkan kepada Allah Subhana Wata’ala atas segala rahmat, nikmat serta karunia-Nya, sehingga penulis dapat menyelesaikan tugas akhir dengan judul “**Prediksi Pola Henti Jantung Berdasarkan Delapan Data Tanda Vital Menggunakan Metode *Recurrent Neural Network***”.

Selama menyusun tugas akhir ini, penulis banyak mendapatkan bantuan, bimbingan dan dukungan dari berbagai pihak baik secara langsung maupun secara tidak langsung sehingga penulis mampu menyelesaikan tugas akhir ini secara tepat waktu. Pada kesempatan ini, penulis ingin mengucapkan rasa syukur kepada Allah SWT dan menyampaikan terimakasih kepada semua pihak yang terlibat antara lain:

1. Kedua orang tua tercinta, ayah dan ibu yang selalu mendoakan dan memberikan nasihat dengan penuh kasih dan sayang.
2. Saudari satu-satunya, adik tersayang Zahra Putri Rafika yang telah memberikan semangat bagi penulis.
3. Bapak Prof. Dr. Ir. M. Said, M.Sc selaku Plt Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Bapak Dr. Ir. Sukemi, M.T. selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
5. Bapak Dr. Firdaus, M.Kom selaku Dosen Pembimbing Skripsi yang telah membantu membimbing penulis dalam menyelesaikan Skripsi.
6. Ibu Prof. Ir. Siti Nurmaini, M.T., Ph.D. selaku Dosen Penguji skripsi yang banyak memberi ilmu dan masukan dalam penulisan skripsi.
7. Mbak Anggun Islami M.Kom selaku asisten Laboratorium Intelligent Systems Research Group (ISysRG) yang telah memberikan dukungan serta membimbing penulis dalam penulisan Skripsi.
8. Terima kasih kepada Intelligent System Research Group (ISysRG) atas bantuan infrastuktur dalam menyelesaikan skripsi.

9. Teman – teman di Laboratorium *Intelligent Systems Research Group* (IsysRG) dan teman – teman jurusan sistem komputer kelas A.
10. Muhammad Rezky Hamesi Akhyar yang banyak memberikan bantuan dan dukungan bagi penulis dalam penyusunan skripsi.

Dalam penyusunan tugas akhir ini, penulis menyadari bahwa masih banyak terdapat kekurangan. Untuk itu, penulis mengharapkan masukan berupa kritik dan saran yang membangun demi kesempurnaan di masa depan. Akhir kata penulis berharap, semoga tugas akhir ini dapat menjadi amal ibadah dan bermanfaat bagi orang lain.

Indralaya, 27 Juni 2023

Penulis,



Salwa Ayu Rafika  
NIM. 09011181924012

**Prediksi Pola Henti Jantung Berdasarkan Delapan Data Tanda Vital  
Menggunakan Metode *Recurrent Neural Network***

**Salwa Ayu Rafika (09011181924012)**

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

Email : [salwa.samsung11111@gmail.com](mailto:salwa.samsung11111@gmail.com)

**ABSTRAK**

Kemampuan untuk memprediksi pola Henti Jantung (*Cardiac Arrest*) dengan tingkat akurasi yang tinggi dapat membantu dalam pencegahan dan penanganan yang lebih efektif. Penelitian ini berfokus pada prediksi pola henti jantung berdasarkan delapan data tanda vital menggunakan metode *Recurrent Neural Network* (RNN) dengan arsitektur LSTM dan Bi-LSTM. Dalam upaya mengatasi data yang tidak seimbang, digunakan teknik *undersampling* dan teknik pembobotan kelas dengan pendekatan *cost sensitive learning*. Untuk mengisi nilai yang kosong pada dataset, penelitian ini menggunakan teknik imputasi Interpolasi Linear dan teknik imputasi *Deep Learning* yaitu *Autoencoder* dan *U-Net*. Performa terbaik dicapai oleh model *cost sensitive* Bi-LSTM (CSBi-LSTM) tanpa melakukan *undersampling* pada kelas mayor. Adapun teknik imputasi yang diterapkan adalah Interpolasi Linear pada total data dan rentang prediksi 60 menit. Hasil evaluasi model CSBi-LSTM pada metrik akurasi, sensitivitas, presisi, f1-score dan spesifisitas masing-masing sebesar 95%, 95%, 5%, 10% dan 100%.

**Keywords** : *Forecasting, Pola Henti Jantung, Multivariate Time Series, SMOTE-ENN, Undersampling, Cost Sensitive Learning, Recurrent Neural Network*

***Cardiac Arrest Pattern Prediction Based on Eight Vital Signs Data Using the  
Recurrent Neural Network Method***

**Salwa Ayu Rafika (09011181924012)**

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

Email : [salwa.samsung11111@gmail.com](mailto:salwa.samsung11111@gmail.com)

**ABSTRACT**

*The ability to predict patterns of Cardiac Arrest with high accuracy can significantly contribute to more effective prevention and treatment. This research focuses on predicting patterns of Cardiac Arrest based on eight vital sign data using Recurrent Neural Network (RNN) methods with LSTM and Bi-LSTM architectures. In order to address the issue of imbalanced data, undersampling techniques and class weighting with cost-sensitive learning approach are employed. To fill in missing values in the dataset, this study utilizes Linear Interpolation as well as Deep Learning techniques such as Autoencoder and U-Net for data imputation. The best performance is achieved by the cost-sensitive Bi-LSTM (CSBi-LSTM) model without undersampling the majority class. Linear Interpolation is applied for data imputation with a total data duration and prediction range of 60 minutes. The evaluation results of the CSBi-LSTM model on accuracy, sensitivity, precision, f1-score, and specificity metrics are 95%, 95%, 5%, 10%, and 100% respectively.*

**Keywords :** *Forecasting, Cardiac Arrest Pattern, Multivariate Time Series, SMOTE-ENN, Undersampling, Cost Sensitive Learning, Recurrent Neural Network*



## 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>viii</b>
<b>DAFTAR ISI.....</b>	<b>ix</b>
<b>DAFTAR GAMBAR.....</b>	<b>xii</b>
<b>DAFTAR TABEL .....</b>	<b>xiv</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Tujuan.....	3
1.3 Rumusan Masalah .....	3
1.4 Batasan Masalah.....	3
1.5 Metodologi Penelitian .....	4
1.6 Sistematika Penelitian .....	5
<b>BAB II TINJAUAN PUSTAKA .....</b>	<b>6</b>
2.1 <i>Forecasting</i> .....	6
2.2 <i>Artificial Intelligence</i> .....	7
2.3 <i>Deep Learning</i> .....	8
2.4 Recurrent Neural Network .....	10
2.5 <i>Long Short-Term Memory</i> .....	10
2.6 <i>Bidirectional Long Short-Term Memory</i> .....	12
2.7 <i>Time Series Data</i> .....	13
2.8 <i>Imbalance Data</i> .....	13
2.9 <i>Undersampling data</i> .....	14
2.10 <i>SMOTE-ENN</i> .....	14
2.11 <i>Cost Sensitive Learning</i> .....	15
2.12 Data Tanda Vital MIMIC-III.....	16
2.13 Pengukuran Kinerja .....	16
2.13.1 <i>Confusion Matrix</i> .....	16

2.13.2	Akurasi .....	17
2.13.3	Presisi .....	18
2.13.4	Sensitivitas .....	18
2.13.5	Spesifisitas .....	18
2.13.6	F1-Score .....	18
<b>BAB III METODOLOGI PENELITIAN .....</b>		<b>19</b>
3.1	Kerangka Kerja.....	19
3.2	Akuisisi Data .....	21
3.3	Pra-pemrosesan Data.....	23
3.3.1	Pembersihan Data .....	23
3.3.2	Imputasi Data .....	27
3.3.3	Normalisasi Data.....	28
3.3.4	Membuat Label .....	29
3.3.5	Seleksi Fitur .....	29
3.3.6	<i>Split Data</i> .....	32
3.3.7	<i>K-Fold Cross Validation</i> .....	33
3.4	Pelatihan Model.....	34
3.4.1	<i>Bi-LSTM SMOTE-ENN</i> .....	34
3.4.2	<i>CSBi-LSTM</i> .....	35
3.4.3	<i>CSBi-LSTM SMOTE-ENN</i> .....	36
3.5	Evaluasi Model.....	37
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>		<b>38</b>
4.1	Hasil Percobaan 1 .....	38
4.1.1	<i>Bi-LSTM SMOTE-ENN</i> .....	38
4.1.2	<i>CSBi-LSTM</i> .....	40
4.1.3	<i>CSBi-LSTM SMOTE-ENN</i> .....	43
4.1.4	Model terbaik Percobaan 1 .....	46
4.2	Hasil Percobaan 2.....	46
4.2.1	Evaluasi model <i>CSBi-LSTM</i> dengan total panjang data 60 menit dan rentang prediksi 60 menit teknik imputasi <i>AutoEncoder</i> .....	47
4.2.2	Evaluasi model <i>CSBi-LSTM</i> dengan total panjang data 60 menit dan rentang prediksi 1440 menit teknik imputasi <i>AutoEncoder</i> .....	49
4.2.3	Evaluasi model <i>Bi-LSTM</i> dengan total panjang data 60 menit dan rentang prediksi 60 menit.....	52

4.2.4	Evaluasi model <i>LSTM</i> dengan total panjang data 60 menit dan rentang prediksi 60 menit.....	55
4.2.5	Evaluasi model <i>Bi-LSTM</i> dengan teknik <i>Undersampling</i> .....	58
4.2.6	Evaluasi model <i>LSTM</i> dengan teknik <i>Undersampling</i> .....	60
4.2.7	Model terbaik percobaan 2.....	63
4.3	Percobaan 3 .....	64
4.3.1	Evaluasi model <i>LSTM</i> dengan teknik <i>undersampling</i> dan imputasi <i>U-Net</i> .....	64
4.3.2	Evaluasi model <i>CSBi-LSTM</i> dengan teknik imputasi <i>U-Net</i> .....	67
4.4	Rangkuman dan Model terbaik penelitian.....	69
<b>BAB V KESIMPULAN .....</b>		<b>70</b>
<b>DAFTAR PUSTAKA .....</b>		<b>71</b>

## DAFTAR GAMBAR

<b>Gambar 2.1</b> Deep Learning[20].....	9
<b>Gambar 2.2</b> Arsitektur RNN[24].....	10
<b>Gambar 2.3</b> Arsitektur LSTM[27].....	11
<b>Gambar 2.4</b> Arsitektur Bi-LSTM[31] .....	12
<b>Gambar 2.5</b> Ilustrasi imbalance data pada dataset tanda vital MIMIC-III.....	14
<b>Gambar 2.6</b> SMOTE-ENN[36] .....	15
<b>Gambar 3.1</b> Kerangka Kerja.....	20
<b>Gambar 3.2</b> Akuisisi Data[44].....	22
<b>Gambar 3.3</b> Sampel data tanda vital pasien ICU id 200001 yang didapatkan setelah akuisisi data.....	22
<b>Gambar 3.4</b> Sebaran data dari delapan tanda vital .....	24
<b>Gambar 3.5</b> Sampel data tanda vital pasien ICU id 200011.....	25
<b>Gambar 3.6</b> Sampel data tanda vital pasien ICU id 200012.....	25
<b>Gambar 3.7</b> Proses pemisahan data rekam yang tidak reguler.....	26
<b>Gambar 3.8</b> Proses menghapus data rekam kurang dari 1000 data.....	26
<b>Gambar 3.9</b> Sampel nilai tanda vital sebelum diimputasi .....	27
<b>Gambar 3.10</b> Sampel nilai tanda vital setelah diimputasi .....	27
<b>Gambar 3.11</b> Sampel data tanda vital sebelum dinormalisasi .....	28
<b>Gambar 3.12</b> Sampel data tanda vital setelah dinormalisasi .....	28
<b>Gambar 3.13</b> Banyak data 15 menit rentang prediksi 30 menit .....	30
<b>Gambar 3.14</b> Banyak data 15 menit rentang prediksi 60 menit .....	30
<b>Gambar 3.15</b> Banyak data 15 menit rentang prediksi 120 menit .....	30
<b>Gambar 3.16</b> Banyak data 60 menit rentang prediksi 30 menit .....	31
<b>Gambar 3.17</b> Banyak data 60 menit rentang prediksi 60 menit.....	31
<b>Gambar 3.18</b> Banyak data 60 menit rentang prediksi 120 menit .....	31
<b>Gambar 3.19</b> Banyak data 60 menit rentang prediksi 1440 menit .....	32
<b>Gambar 4.1</b> Confusion Matrix Bi-LSTM SMOTE-ENN.....	39
<b>Gambar 4.2</b> Confusion Matrix CSBi-LSTM .....	42
<b>Gambar 4.3</b> Confusion Matrix CSBi-LSTM SMOTE-ENN.....	45
<b>Gambar 4.4</b> Confusion matrix CSBi-LSTM dengan data 60 menit dan rentang prediksi 60 menit.....	48

<b>Gambar 4.5</b> Confusion matrix CSBi-LSTM dengan total panjang data 60 menit dan rentang prediksi 1440 menit.....	51
<b>Gambar 4.6</b> Confusion matrix Bi-LSTM .....	54
<b>Gambar 4.7</b> Confusion matrix LSTM .....	57
<b>Gambar 4.8</b> Confusion matrix Bi-LSTM dengan teknik undersampling .....	59
<b>Gambar 4.9</b> Confusion matrix LSTM dengan teknik undersampling .....	62
<b>Gambar 4.10</b> Confusion Matrix LSTM (U-Net) .....	66
<b>Gambar 4.11</b> Metrik evaluasi LSTM (U-Net).....	66
<b>Gambar 4. 12</b> Confusion Matrix CSBi-LSTM (U-Net) .....	68
<b>Gambar 4.13</b> Metrik evaluasi CSBi-LSTM (U-Net).....	69

## DAFTAR TABEL

<b>Tabel 2.1</b> Confusion Matrix .....	17
<b>Tabel 3.1</b> Tabel database MIMIC-III[43].....	21
<b>Tabel 3.2</b> Rincian jumlah id pasien, dataset dan total rekaman .....	27
<b>Tabel 3.3</b> Karakteristik pasien CA dan Non-CA[45] .....	29
<b>Tabel 3.4</b> Rincian split data.....	32
<b>Tabel 3.5</b> Rincian jumlah pembagian kelas dengan k-fold cross validation.....	33
<b>Tabel 3.6</b> Konfigurasi Hyperparameter.....	34
<b>Tabel 3.7</b> Rincian pembobotan data menggunakan cost sensitive learning percobaan 1 .....	35
<b>Tabel 3.8</b> Rincian pembobotan data menggunakan cost sensitive learning percobaan 2 .....	36
<b>Tabel 3.9</b> Konfigurasi parameter yang diatur pada percobaan 1.....	37
<b>Tabel 4.1</b> Grafik akurasi dan grafik loss Bi-LSTM SMOTE-ENN .....	38
<b>Tabel 4.2</b> Metrik evaluasi Bi-LSTM SMOTE-ENN .....	40
<b>Tabel 4.3</b> Grafik akurasi dan grafik loss CSBi-LSTM.....	41
<b>Tabel 4.4</b> Metrik evaluasi CSBi-LSTM .....	42
<b>Tabel 4.5</b> Grafik akurasi dan grafik loss CSBi-LSTM SMOTE-ENN .....	43
<b>Tabel 4.6</b> Metrik evaluasi CSBi-LSTM SMOTE-ENN .....	45
<b>Tabel 4.7</b> Perbandingan hasil evaluasi model pada percobaan 1 .....	46
<b>Tabel 4.8</b> Grafik akurasi dan loss CSBi-LSTM dengan data 60 menit dan rentang prediksi 60 menit.....	47
<b>Tabel 4.9</b> Metrik evaluasi CSBi-LSTM dengan total panjang data 60 menit dan rentang prediksi 60 menit.....	49
<b>Tabel 4.10</b> Grafik akurasi dan loss pada proses training dengan total panjang data 60 menit dan rentang prediksi 1440 menit.....	50
<b>Tabel 4.11</b> Metrik evaluasi CSBi-LSTM dengan total panjang data 60 menit dan rentang prediksi 1440 menit.....	52
<b>Tabel 4.12</b> Grafik akurasi dan grafik loss Bi-LSTM .....	53
<b>Tabel 4.13</b> Metrik evaluasi Bi-LSTM .....	55
<b>Tabel 4.14</b> Grafik akurasi dan grafik loss LSTM.....	56
<b>Tabel 4.15</b> Metrik evaluasi LSTM .....	57

<b>Tabel 4.16</b> Grafik akurasi dan grafik loss Bi-LSTM dengan teknik Undersampling .....	58
<b>Tabel 4.17</b> Metrik evaluasi Bi-LSTM dengan teknik Undersampling .....	60
<b>Tabel 4.18</b> Grafik akurasi dan grafik loss LSTM.....	61
<b>Tabel 4.19</b> Metrik evaluasi LSTM dengan teknik undersampling.....	62
<b>Tabel 4.20</b> Perbandingan metrik evaluasi model pada percobaan 2 .....	63
<b>Tabel 4.21</b> Grafik akurasi dan grafik loss LSTM (U-Net) .....	65
<b>Tabel 4.22</b> Grafik akurasi dan grafik loss CSBi-LSTM (U-Net) .....	67
<b>Tabel 4. 23</b> Rangkuman model penelitian.....	69

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Perkembangan *Artificial Intelligence* (AI) telah membawa banyak inovasi dan kemajuan dalam berbagai bidang. Di bidang kesehatan, teknologi AI untuk *forecasting* terus berkembang dengan pesat dalam beberapa tahun terakhir. Berkat kemampuan mesin untuk memproses data dalam skala besar, teknologi AI mulai dimanfaatkan untuk melakukan prediksi kemungkinan terjadinya penyakit atau kondisi kesehatan pasien di masa depan. Termasuk untuk memprediksi Henti Jantung (*Cardiac Arrest/CA*) pada pasien perawatan intensif[1].

Namun, pada kenyataannya masih terdapat tantangan dalam membuat model prediksi yang akurat. Salah satu penyebab utama kurang akuratnya model dalam memprediksi CA yaitu data yang tidak seimbang [2]. Kondisi seperti itu sering terjadi pada dataset medis, dimana data positif atau abnormal berjumlah sedikit (kelas minor). Sementara itu, data negatif atau normal berjumlah banyak (kelas mayor), sehingga menimbulkan permasalahan bias pada kinerja model prediksi. Permasalahan bias pada kinerja model prediksi merupakan permasalahan yang muncul ketika nilai kinerja model prediksi menunjukkan nilai akurasi yang tinggi. Namun, hal itu sebenarnya model cenderung hanya mampu mempelajari data kelas mayor dengan baik sedangkan pada saat memprediksi data kelas minor, model memiliki kinerja prediksi yang sangat buruk [3]. Dapat dilihat dari penggunaan metode prediksi pada penelitian sebelumnya [4][5], kedua penelitian ini hanya menerapkan teknik evaluasi kinerja berupa perhitungan nilai akurasi tanpa memperhatikan kondisi data dalam keadaan seimbang atau tidak.

Untuk mengatasi masalah ketidakseimbangan data, terdapat tiga metode yang dapat diterapkan yaitu metode tingkat data (*data-level*) dan metode tingkat algoritma (*algorithm-level*) serta metode hibrid (*hybrid-level*)[6]. Pada metode tingkat data terdapat tiga teknik *resampling* data untuk membuat data menjadi seimbang diantaranya *oversampling*, *undersampling* dan *hybrid sampling*[7]. Penelitian yang dilakukan oleh [8] menggunakan berbagai metode tingkat data



termasuk SMOTE, *Cluster Centroids*, *Near Miss*, *Random Under Sampler* dan SMOTEENN untuk mengatasi masalah ketidakseimbangan data. Data yang digunakan, diambil dari database MIMIC-III berupa data klinis 30 jam dari setiap pasien sepsis yang terdiri 79 CA dan 4532 normal. Diusulkan berbagai algoritma *machine learning* (*SVM*, *Decision Tree*, *Logistic Regression*, *KNN*, *GaussianNB*) sebagai *classifier* untuk melakukan prediksi CA pada pasien sepsis. Didapatkan hasil terbaik menggunakan algoritma SVM dengan metode SMOTE. Nilai sensitivitas, presisi dan f1-score berturut-turut adalah 70%, 17% dan 27%.

Selain dengan cara menerapkan metode tingkat data, peningkatan keakuratan model prediksi pada data yang tidak seimbang dapat dilakukan dengan menggunakan metode tingkat algoritma yang ideal. Pada metode tingkat algoritma biasanya dilakukan modifikasi pada algoritma prediksi dengan lebih memperhatikan kelas minor untuk diterapkan skema pembobotan (*weight*) seperti metode *cost-sensitive learning*. Model algoritma yang cocok untuk memprediksi CA dengan karakteristik data tanda vital yang direkam secara *time series* yaitu *Recurrent Neural Network* (RNN)[9]. Saat ini, metode RNN merupakan salah satu model *deep learning* paling populer dalam pemodelan data sekuensial, dan banyak digunakan untuk tugas peramalan deret waktu. RNN memiliki kemampuan untuk mengingat informasi masa lalu dan menggunakannya untuk memprediksi output pada masa depan. Oleh karena itu, RNN sangat cocok untuk tugas *forecasting*[10]. Arsitektur – arsitektur dari RNN seperti LSTM dan Bi-LSTM sangat disarankan karena telah banyak penelitian yang membuktikan keberhasilannya dalam menghasilkan kinerja dan nilai akurasi yang baik untuk tugas prediksi dengan data *time series* seperti pada penelitian [11], [12] dan [13]. Ketiga penelitian tersebut berhasil mencapai nilai akurasi di atas 90%.

Berdasarkan beberapa penelitian yang telah dilakukan, membuktikan bahwa metode tingkat data seperti SMOTE dan metode tingkat algoritma seperti RNN dapat meningkatkan keakuratan model prediksi pada data yang tidak seimbang. Oleh karena itu, dilakukan penelitian mengenai Prediksi Pola Henti Jantung Berdasarkan Delapan Data Tanda Vital Menggunakan Metode *Recurrent Neural Network* dengan menggunakan strategi yang dapat diterapkan yaitu metode tingkat data dan tingkat algoritma serta tingkat hibrid.

## 1.2 Tujuan

Tujuan dari penelitian dalam tugas akhir ini adalah sebagai berikut:

1. Merancang dan melatih model prediksi pada data yang tidak seimbang menggunakan metode RNN untuk memprediksi CA pada pasien unit perawatan intensif secara akurat.
2. Mengukur kinerja model prediksi menggunakan parameter metrik evaluasi untuk menentukan metode yang terbaik dalam memprediksi CA.

## 1.3 Rumusan Masalah

Berdasarkan latar belakang, dapat disimpulkan bahwa masalah dalam penelitian ini adalah kurangnya keakuratan model prediksi CA pada data yang tidak seimbang. Data berlabel CA berjumlah jauh lebih sedikit dibandingkan jumlah data berlabel non CA. Oleh karena itu, penulis melakukan penelitian bagaimana cara model dapat memprediksi terjadinya CA secara akurat dengan jumlah data yang tidak seimbang.

## 1.4 Batasan Masalah

Batasan masalah dalam penelitian pada tugas akhir ini adalah sebagai berikut:

1. Dataset yang digunakan diambil dalam database MIMIC-III berupa dataset tanda vital time series pada pasien unit perawatan intensif.
2. Menggunakan bahasa pemrograman *python* untuk pengolahan data dan pembangunan model prediksi.
3. Menggunakan salah satu arsitektur metode *Recurrent Neural Network* yaitu LSTM dan Bi-LSTM.
4. Metrik evaluasi yang digunakan untuk mengukur kinerja model berupa akurasi, presisi, specificity, recall dan F1-Score.

## **1.5 Metodologi Penelitian**

Metodologi yang digunakan pada penyusunan tugas akhir ini adalah sebagai berikut:

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

Pada metode ini melakukan kegiatan mencari dan mengumpulkan berbagai macam referensi berupa literatur yang didapatkan dari berbagai sumber seperti di internet, buku, artikel dan lain sebagainya mengenai tema penelitian ini yaitu Henti Jantung menggunakan metode RNN.

### **1.5.2 Metode Konsultasi**

Pada metode ini penulis berkonsultasi kepada orang - orang yang memiliki pengetahuan dalam mengatasi masalah ketidakseimbangan data serta memiliki pengalaman dalam membangun model prediksi agar tujuan dari penelitian ini dapat tercapai.

### **1.5.3 Metode Pembuatan Model**

Pada metode ini penulis merancang pembangunan model arsitektur menggunakan bahasa pemrograman python. Model yang dibangun digunakan untuk melakukan prediksi CA pada pasien dalam rentang waktu ke depan yang telah ditentukan.

### **1.5.4 Metode Pengujian dan Validasi**

Pada metode ini penulis melakukan pengujian dan validasi terhadap model menggunakan dataset tanda vital pasien unit perawatan intensif untuk mengetahui batas kinerja model yang telah dibangun.

### **1.5.5 Metode Hasil dan Analisa**

Pada metode ini penulis melakukan analisa terhadap hasil dari penelitian tugas akhir ini mengenai kualitas kinerja model yang telah dibangun beserta kelebihan dan kekurangannya.

### **1.5.6 Metode Penarikan Kesimpulan dan Saran**

Pada metode ini penulis menarik kesimpulan atas hasil dari penelitian ini serta dilengkapi dengan saran yang dirangkum dengan ringkas untuk memperjelas

hasil akhir dari penelitian ini yang dapat dijadikan bahan referensi untuk penelitian selanjutnya.

## **1.6 Sistematika Penelitian**

Sistematika penulisan digunakan agar penulisan tugas akhir ini dapat tersusun secara rapi, terstruktur dan jelas. Adapun sistematika penelitian pada tugas akhir ini adalah sebagai berikut:

### **BAB I PENDAHULUAN**

Pada bab pendahuluan akan berisi penjelasan mengenai latar belakang, tujuan, manfaat, perumusan dan batasan masalah, serta metodologi dan sistematika penelitian dari topik penelitian yang telah dipilih.

### **BAB II TINJAUAN PUSTAKA**

Pada bab tinjauan pustaka akan berisi penjelasan mengenai dasar - dasar teori sebagai landasan dalam penulisan tugas akhir ini mengenai prediksi CA, karakteristik dataset dan arsitektur yang digunakan dalam penelitian.

### **BAB III METODOLOGI PENELITIAN**

Pada bab metodologi penelitian akan berisi penjelasan secara rinci dan bertahap mengenai kerangka kerja dan metode yang akan digunakan dalam penelitian ini.

### **BAB IV HASIL DAN ANALISIS**

Pada bab hasil dan analisis akan berisi pembahasan mengenai hasil dan analisa dari hasil yang didapatkan dari penelitian yang telah dikerjakan.

### **BAB V PENUTUP**

Pada bab penutup akan berisi kesimpulan dari hasil penelitian yang telah dilaksanakan serta saran untuk penelitian selanjutnya tentang prediksi CA.

## DAFTAR PUSTAKA

- [1] B. Soudan, F. F. Dandachi, and A. B. Nassif, "Attempting cardiac arrest prediction using artificial intelligence on vital signs from Electronic Health Records," *Smart Heal.*, vol. 25, p. 100294, Sep. 2022, doi: 10.1016/J.SMHL.2022.100294.
- [2] B. Rifai, "Algoritma Neural Network Untuk Prediksi," *Techno Nusa Mandiri*, vol. IX, no. 1, pp. 1–9, 2013.
- [3] Y. Sun, A. K. C. Wong, and M. S. Kamel, "Classification of imbalanced data: A review," *Int. J. Pattern Recognit. Artif. Intell.*, vol. 23, no. 4, pp. 687–719, 2009, doi: 10.1142/S0218001409007326.
- [4] H. K. Chang *et al.*, "Early detecting in-hospital cardiac arrest based on machine learning on imbalanced data," *2019 IEEE Int. Conf. Healthc. Informatics, ICHI 2019*, pp. 1–10, 2019, doi: 10.1109/ICHI.2019.8904504.
- [5] N. Liu *et al.*, "An intelligent scoring system and its application to cardiac arrest prediction," *IEEE Trans. Inf. Technol. Biomed.*, vol. 16, no. 6, pp. 1324–1331, 2012, doi: 10.1109/TITB.2012.2212448.
- [6] E. Esenogho, I. D. Mienye, T. G. Swart, K. Aruleba, and G. Obaido, "A Neural Network Ensemble with Feature Engineering for Improved Credit Card Fraud Detection," *IEEE Access*, vol. 10, pp. 16400–16407, 2022, doi: 10.1109/ACCESS.2022.3148298.
- [7] Z. Chen, J. Duan, L. Kang, and G. Qiu, "A hybrid data-level ensemble to enable learning from highly imbalanced dataset," *Inf. Sci. (Ny.)*, vol. 554, pp. 157–176, Apr. 2021, doi: 10.1016/J.INS.2020.12.023.
- [8] 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.
- [9] S. Liu, J. Yao, and M. Motani, "Early Prediction of Vital Signs Using Generative Boosting via LSTM Networks," pp. 437–444, 2019.
- [10] R. Khaldi, A. El Afia, R. Chiheb, and S. Tabik, "What is the best RNN-cell structure to forecast each time series behavior?," *Expert Syst. Appl.*, vol. 215, p. 119140, Apr. 2023, doi: 10.1016/J.ESWA.2022.119140.
- [11] H. Wang, X. Zhao, X. Zhang, D. Wu, and X. Du, "Long Time Series Land Cover Classification in China from 1982 to 2015 Based on Bi-LSTM Deep Learning," *Remote Sens. 2019, Vol. 11, Page 1639*, vol. 11, no. 14, p. 1639, Jul. 2019, doi: 10.3390/RS11141639.
- [12] M. O. Alassafi, M. Jarrah, and R. Alotaibi, "Time series predicting of COVID-19 based on deep learning," *Neurocomputing*, vol. 468, pp. 335–344, Jan. 2022, doi: 10.1016/J.NEUCOM.2021.10.035.

- [13] S. Shastri, K. Singh, S. Kumar, P. Kour, and V. Mansotra, "Time series forecasting of Covid-19 using deep learning models: India-USA comparative case study," *Chaos, Solitons & Fractals*, vol. 140, p. 110227, Nov. 2020, doi: 10.1016/J.CHAOS.2020.110227.
- [14] A. O. Aseeri, "Effective RNN-based forecasting methodology design for improving short-term power load forecasts: Application to large-scale power-grid time series," *J. Comput. Sci.*, p. 101984, Mar. 2023, doi: 10.1016/J.JOCS.2023.101984.
- [15] F. von Bülow and T. Meisen, "A review on methods for state of health forecasting of lithium-ion batteries applicable in real-world operational conditions," *J. Energy Storage*, vol. 57, p. 105978, Jan. 2023, doi: 10.1016/J.EST.2022.105978.
- [16] A. G. Olabi *et al.*, "Application of artificial intelligence for prediction, optimization, and control of thermal energy storage systems," *Therm. Sci. Eng. Prog.*, vol. 39, p. 101730, Mar. 2023, doi: 10.1016/J.TSEP.2023.101730.
- [17] S. Bacchi *et al.*, "Prediction of general medical admission length of stay with natural language processing and deep learning: a pilot study," *Intern. Emerg. Med.*, vol. 15, no. 6, pp. 989–995, Sep. 2020, doi: 10.1007/S11739-019-02265-3/METRICS.
- [18] J. Park, W. H. Lee, K. T. Kim, C. Y. Park, S. Lee, and T. Y. Heo, "Interpretation of ensemble learning to predict water quality using explainable artificial intelligence," *Sci. Total Environ.*, vol. 832, no. January, p. 155070, 2022, doi: 10.1016/j.scitotenv.2022.155070.
- [19] F. K. Alarfaj, I. Malik, H. U. Khan, N. Almusallam, M. Ramzan, and M. Ahmed, "Credit Card Fraud Detection Using State-of-the-Art Machine Learning and Deep Learning Algorithms," *IEEE Access*, vol. 10, pp. 39700–39715, 2022, doi: 10.1109/ACCESS.2022.3166891.
- [20] I. Rizwan I Haque and J. Neubert, "Deep learning approaches to biomedical image segmentation," *Informatics Med. Unlocked*, vol. 18, p. 100297, 2020, doi: 10.1016/j.imu.2020.100297.
- [21] N. M. Rezk, M. Purnaprajna, T. Nordstrom, and Z. Ul-Abdin, "Recurrent Neural Networks: An Embedded Computing Perspective," *IEEE Access*, vol. 8, pp. 57967–57996, 2020, doi: 10.1109/ACCESS.2020.2982416.
- [22] N. Aziz, M. H. A. Abdullah, and A. N. Zaidi, "Predictive Analytics for Crude Oil Price Using RNN-LSTM Neural Network," *2020 Int. Conf. Comput. Intell. ICCI 2020*, no. October, pp. 173–178, 2020, doi: 10.1109/ICCI51257.2020.9247665.
- [23] J. Xiao and Z. Zhou, "Research Progress of RNN Language Model," *Proc. 2020 IEEE Int. Conf. Artif. Intell. Comput. Appl. ICAICA 2020*, pp. 1285–1288, 2020, doi: 10.1109/ICAICA50127.2020.9182390.
- [24] P. Venugopal and T. Vigneswaran, "State-of-health estimation of Li-ion

- batteries in electric vehicle using InDRNN under variable load condition,” *Energies*, vol. 12, no. 22, Nov. 2019, doi: 10.3390/EN12224338.
- [25] Y. Hua, Z. Zhao, R. Li, X. Chen, Z. Liu, and H. Zhang, “Deep Learning with Long Short-Term Memory for Time Series Prediction,” *IEEE Commun. Mag.*, vol. 57, no. 6, pp. 114–119, Jun. 2019, doi: 10.1109/MCOM.2019.1800155.
- [26] A. Pulver and S. Lyu, “LSTM with working memory,” *Proc. Int. Jt. Conf. Neural Networks*, vol. 2017-May, pp. 845–851, Jun. 2017, doi: 10.1109/IJCNN.2017.7965940.
- [27] X. H. Le, H. V. Ho, G. Lee, and S. Jung, “Application of Long Short-Term Memory (LSTM) neural network for flood forecasting,” *Water (Switzerland)*, vol. 11, no. 7, 2019, doi: 10.3390/W11071387.
- [28] W. Yue and L. Li, “Sentiment analysis using word2vec-cnn-bilstm classification,” *2020 7th Int. Conf. Soc. Netw. Anal. Manag. Secur. SNAMS 2020*, pp. 3–7, 2020, doi: 10.1109/SNAMS52053.2020.9336549.
- [29] A. Aziz Sharfuddin, M. Nafis Tihami, and M. Saiful Islam, “A Deep Recurrent Neural Network with BiLSTM model for Sentiment Classification,” *2018 Int. Conf. Bangla Speech Lang. Process. ICBSLP 2018*, pp. 1–4, 2018, doi: 10.1109/ICBSLP.2018.8554396.
- [30] S. Siami-Namini, N. Tavakoli, and A. S. Namin, “The Performance of LSTM and BiLSTM in Forecasting Time Series,” *Proc. - 2019 IEEE Int. Conf. Big Data, Big Data 2019*, pp. 3285–3292, Dec. 2019, doi: 10.1109/BIGDATA47090.2019.9005997.
- [31] Z. Cui, R. Ke, Z. Pu, and Y. Wang, “Deep Bidirectional and Unidirectional LSTM Recurrent Neural Network for Network-wide Traffic Speed Prediction,” Jan. 2018, Accessed: May 27, 2023. [Online]. Available: <http://arxiv.org/abs/1801.02143>.
- [32] 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.
- [33] J. K. Sethi and M. Mittal, “Analysis of air quality using univariate and multivariate time series models,” *Proc. Conflu. 2020 - 10th Int. Conf. Cloud Comput. Data Sci. Eng.*, pp. 823–827, 2020, doi: 10.1109/Confluence47617.2020.9058303.
- [34] J. M. Johnson and T. M. Khoshgoftaar, “Survey on deep learning with class imbalance,” *J. Big Data*, vol. 6, no. 1, pp. 1–54, Dec. 2019, doi: 10.1186/S40537-019-0192-5/TABLES/18.
- [35] M. S. Shelke, P. R. Deshmukh, and P. V. K. Shandilya, “A Review on Imbalanced Data Handling Using Undersampling and Oversampling Technique,” *Int. J. Recent Trends Eng. Res.*, vol. 3, no. 4, pp. 444–449, 2017, doi: 10.23883/ijrter.2017.3168.0uwxm.
- [36] “Illustration of SMOTE+ENN. | Download Scientific Diagram.”

[https://www.researchgate.net/figure/Illustration-of-SMOTE-ENN\\_fig1\\_353356456](https://www.researchgate.net/figure/Illustration-of-SMOTE-ENN_fig1_353356456) (accessed Jun. 13, 2023).

- [37] Y. Sun, Y. Sun, and H. Dai, “Two-stage cost-sensitive learning for data streams with concept drift and class imbalance,” *IEEE Access*, vol. 8, pp. 191942–191955, 2020, doi: 10.1109/ACCESS.2020.3031603.
- [38] C. Elkan, “The Foundations of Cost-Sensitive Learning.”
- [39] O. Altay, M. Ulas, and K. E. Alyamac, “Prediction of the Fresh Performance of Steel Fiber Reinforced Self-Compacting Concrete Using Quadratic SVM and Weighted KNN Models,” *IEEE Access*, vol. 8, pp. 92647–92658, 2020, doi: 10.1109/ACCESS.2020.2994562.
- [40] P. Singh, N. Singh, K. K. Singh, and A. Singh, “Diagnosing of disease using machine learning,” *Mach. Learn. Internet Med. Things Healthc.*, pp. 89–111, Jan. 2021, doi: 10.1016/B978-0-12-821229-5.00003-3.
- [41] A. Kulkarni, D. Chong, and F. A. Batarseh, “Foundations of data imbalance and solutions for a data democracy,” *Data Democr. Nexus Artif. Intell. Softw. Dev. Knowl. Eng.*, pp. 83–106, Jan. 2020, doi: 10.1016/B978-0-12-818366-3.00005-8.
- [42] D. K. Sharma, M. Chatterjee, G. Kaur, and S. Vavilala, “Deep learning applications for disease diagnosis,” *Deep Learn. Med. Appl. with Unique Data*, pp. 31–51, Jan. 2022, doi: 10.1016/B978-0-12-824145-5.00005-8.
- [43] “MIMIC-III Clinical Database v1.4.” <https://physionet.org/content/mimiciii/1.4/> (accessed May 27, 2023).
- [44] A. E. W. Johnson *et al.*, “MIMIC-III, a freely accessible critical care database,” *Sci. Data*, vol. 3, May 2016, doi: 10.1038/SDATA.2016.35.
- [45] 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.
- [46] H. L. Vu, K. T. W. Ng, A. Richter, and C. An, “Analysis of input set characteristics and variances on k-fold cross validation for a Recurrent Neural Network model on waste disposal rate estimation,” *J. Environ. Manage.*, vol. 311, p. 114869, Jun. 2022, doi: 10.1016/J.JENVMAN.2022.114869.