

**PREDIKSI MORTALITAS PADA PASIEN INSTALASI
PERAWATAN INTENSIF MENGGUNAKAN *DEEP
LEARNING***

SKRIPSI

Diajukan Untuk Melengkapi Salah Satu Syarat

Memperoleh Gelar Sarjana Komputer



OLEH :

RAHMADINA MAULIA UTAMI

09011182025003

JURUSAN SISTEM KOMPUTER

FAKULTAS ILMU KOMPUTER

UNIVERSITAS SRIWIJAYA

2024

HALAMAN PENGESAHAN

**PREDIKSI MORTALITAS PADA PASIEN INSTALASI PERAWATAN
INTENSIF MENGGUNAKAN *DEEP LEARNING***

SKRIPSI

Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer

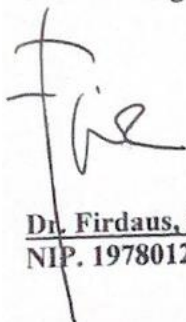
OLEH :

**RAHMADINA MAULIA UTAMI
09011182025003**

Palembang, Agustus 2024

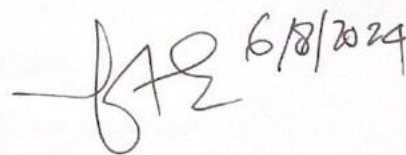
Mengetahui,

Pembimbing Tugas Akhir 1



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

Pembimbing Tugas Akhir 2

 6/8/2024

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

Ketua Jurusan Sistem Komputer 26/8/24


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

HALAMAN PERSETUJUAN

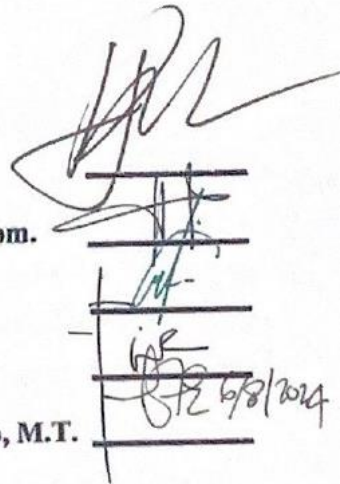
Telah diuji dan lulus pada :

Hari : Rabu

Tanggal : 17 Juli 2024

Tim Penguji :

1. Ketua : Prof. Erwin, M. Si.
2. Sekretaris : Annisa Darmawahyuni, M. Kom.
3. Penguji : Dr. Ahmad Zarkasi, M. T.
4. Pembimbing 1 : Dr. Firdaus, S.T., M.Kom.
5. Pembimbing 2 : Prof. Dr. Ir. Bambang Tutuko, M.T.


A vertical column of handwritten signatures and dates corresponding to the examiners listed on the left. The signatures are written in black ink over horizontal lines. The date '17/7/2024' is written at the bottom of the column.

Mengetahui, *us/17/24*

Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.

NIP. 19661203200604100

HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Rahmadina Maulia Utami

NIM : 09011182025003

Judul : Prediksi Mortalitas pada Pasien Instalasi Perawatan Intensif
Menggunakan *Deep Learning*

Hasil Pengecekan Software Turnitin : 13%

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

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



Palembang,

Agustus 2024



RAHMADINA MAULIA UTAMI

NIM. 09011182025003

KATA PENGANTAR

Puji syukur kehadiran Tuhan Yang Maha Esa atas berkat, rahmat, dan penyertaan-Nya penulis telah diberikan kesehatan, kekuatan, serta kesanggupan sehingga penulis mampu menyelesaikan skripsi ini yang berjudul “Prediksi Mortalitas pada Pasien Instalasi Perawatan Intensif Menggunakan *Deep Learning*”.

Dalam penulis skripsi, penulis masih dalam tahap pembelajaran dan bimbingan. Dengan demikian, penulis menyadari bahwa tanpa bantuan serta petunjuk dari semua pihak, penulis tentu tidak dapat menyelesaikan skripsi ini. Pada kesempatan kali ini saya ingin mengucapkan terima kasih kepada:

1. Allah SWT yang telah memberi penulis berkah dan rahmat-Nya.
2. Orang Tua penulis, Ibu dan Bapak, yang selalu memberikan motivasi, doa, serta dukungannya kepada penulis dan menguatkan dalam menyelesaikan skripsi.
3. Bapak Prof. Dr. Erwin, S.SI,M.SI., selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Bapak Ir. Sukemi, M.T., selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
5. Bapak Dr. Firdaus, S. T., M. Kom. Dan Bapak Prof. Dr. Ir. Bambang Tutuko, M. T., selaku Dosen Pembimbing skripsi penulis yang telah berkenan meluangkan waktu dalam membimbing penulis dalam penyusunan skripsi.
6. Bapak Ahmad Fali Oklilas, M.T., selaku Dosen Pembimbing Akademik penulis pada Program Studi Sistem Komputer.
7. Ibu Anggun Islami, M. Kom. selaku mentor dalam penyelesaian skripsi.
8. Ibu Sari selaku Admin Program Studi Sistem Komputer yang telah membantu administrasi dalam menyelesaikan skripsi.
9. Saudara penulis, Dila dan Ality yang telah menyemangati penulis selama proses penyusunan skripsi.

10. Teman-teman seperjuangan penulis di ISysRG yang telah menemani suka dan duka penulis selama proses penyusunan skripsi dari awal hingga akhir.
11. Teman-teman di BEM KM FASILKOM UNSRI Kabinet Lentera Karya dan Kabinet Askara Akasia yang telah mengajarkan banyak hal kepada penulis dan membuat kenangan baik selama masa perkuliahan penulis.
12. Muhammad Akrom dan keluarga yang telah memberikan dukungan penuh kepada penulis lewat cinta kasihnya dan telah memberikan banyak pengalaman berharga kepada penulis khususnya pada saat kerja praktik.
13. Semua relasi penulis, baik kakak tingkat maupun rekan seangkatan penulis angkatan 2020 yang menjadi teman seperjuangan pada Sistem Komputer, Universitas Sriwijaya.
14. *Last but not least*, penulis ingin berterima kasih kepada diri sendiri karena sudah bertahan dan bekerja keras untuk skripsi ini hingga selesai.

Penulis menyadari bahwa skripsi belum sampai pada batas sempurna. Maka dari itu penulis mengharapkan kritik dan saran yang membangun serta kemakluman agar penulis semakin berkembang dalam masa pembelajaran. Penulis berharap pula agar skripsi dapat bermanfaat dan berguna bagi pihak yang terlibat maupun para pembaca, serta bagi penulis sendiri.

Palembang, Agustus 2024

Penulis,

Rahmadina Maulia Utami
NIM. 09011182025003

PREDIKSI MORTALITAS PADA PASIEN INSTALASI PERAWATAN INTENSIF MENGGUNAKAN *DEEP LEARNING*

RAHMADINA MAULIA UTAMI (09011182025003)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

Email : rahmadinamauliautami@gmail.com

ABSTRAK

Prediksi mortalitas pada pasien unit perawatan intensif sangat penting untuk perencanaan perawatan, alokasi sumber daya, dan pengambilan keputusan medis yang tepat waktu. Untuk meningkatkan akurasi prediksi ini, teknologi kecerdasan buatan telah menunjukkan hasil yang menjanjikan. Penelitian ini bertujuan mengembangkan metode *deep learning* yang dapat meningkatkan akurasi prediksi mortalitas pada pasien unit perawatan intensif, mengatasi nilai hilang dan ketidakseimbangan kelas pada data *time-series multivariate*. Metodologi penelitian mencakup studi literatur, pengumpulan data dari *database* MIMIC-IV, pra-pemrosesan data, pembuatan model, pengujian, validasi model, serta analisis hasil. Tahap pra-pemrosesan meliputi seleksi fitur, pivot data, penyaringan data, *encoding data*, imputasi data, dan penyeimbangan data. Metode *deep learning* yang diterapkan mencakup GRU, LSTM, RNN, CNN, Bi-LSTM, *Stacked LSTM*, dan 1D-MSNet. Imputasi data dilakukan menggunakan interpolasi linear dan XU-Netl, sementara teknik *undersampling* dan SMOTE digunakan untuk mengatasi ketidakseimbangan kelas. Hasil penelitian menunjukkan bahwa metode 1D-MSNet mencapai akurasi 99% pada data training dan 96% pada data validasi serta testing, dengan nilai AUC mendekati 100%, yang mengindikasikan kemampuan prediktif yang sangat tinggi. Kesimpulannya, metode *deep learning*, khususnya 1D-MSNet, efektif dalam meningkatkan akurasi prediksi mortalitas pada pasien ICU. Penggunaan teknik XU-Netl efektif dalam menangani nilai hilang, dan teknik SMOTE efektif dalam mengatasi ketidakseimbangan kelas, sehingga meningkatkan performa model secara signifikan.

Kata Kunci : Prediksi mortalitas, *deep learning*, MIMIC-IV

***MORTALITY PREDICTION IN INTENSIVE CARE
INSTALLATION PATIENTS USING DEEP LEARNING***

RAHMADINA MAULIA UTAMI (09011182025003)

Computer System Department, Computer Science Faculty, Sriwijaya University

Email : rahmadinamauliautami@gmail.com

ABSTRACT

Mortality prediction for patients in intensive care units (ICUs) is crucial for care planning, resource allocation, and timely medical decision-making. To enhance the accuracy of these predictions, artificial intelligence (AI) technology has shown promising results. This study aims to develop deep learning methods to improve the accuracy of mortality predictions for ICU patients, addressing missing values and class imbalance in multivariate time-series data. The research methodology includes literature review, data collection from the MIMIC-IV database, data preprocessing, model development, testing, validation, and result analysis. The preprocessing stage involves feature selection, data pivoting, data filtering, data encoding, data imputation, and data balancing. The deep learning methods applied include GRU, LSTM, RNN, CNN, Bi-LSTM, Stacked LSTM, and 1D-MSNet. Data imputation is performed using linear interpolation and XU-Net, while undersampling and SMOTE techniques are used to address class imbalance. The study results show that the 1D-MSNet method achieves 99% accuracy on training data and 96% on validation and testing data, with an AUC value approaching 100%, indicating very high predictive capability. In conclusion, deep learning methods, particularly 1D-MSNet, are effective in improving the accuracy of mortality predictions for ICU patients. The use of XU-Net is effective in handling missing values, and SMOTE techniques are effective in addressing class imbalance, significantly enhancing model performance.

Keywords : *Mortality prediction, deep learning, MIMIC-IV*

DAFTAR ISI

| | |
|--|------------------------------|
| HALAMAN PENGESAHAN | Error! Bookmark not defined. |
| HALAMAN PERSETUJUAN | Error! Bookmark not defined. |
| HALAMAN PERNYATAAN | Error! Bookmark not defined. |
| KATA PENGANTAR | v |
| ABSTRAK | vii |
| ABSTRACT | viii |
| DAFTAR ISI | ix |
| DAFTAR GAMBAR | xii |
| DAFTAR TABEL | xiv |
| BAB I PENDAHULUAN | 1 |
| 1.1. Latar Belakang | 1 |
| 1.2. Perumusan Masalah | 3 |
| 1.3. Batasan Masalah | 3 |
| 1.4. Tujuan | 4 |
| 1.5. Metodologi Penulisan..... | 4 |
| 1.5.1. Metode Studi Pustaka dan Literatur..... | 4 |
| 1.5.2. Metode Konsultasi | 4 |
| 1.5.3. Metode Pembuatan Model | 4 |
| 1.5.4. Metode Pengujian dan Validasi | 4 |
| 1.5.5. Metode Hasil dan Analisa | 4 |
| 1.5.6. Metode Penarikan Kesimpulan dan Saran | 5 |
| 1.6. Sistematika Penulisan | 5 |
| BAB II TINJAUAN PUSTAKA | 6 |

| | | |
|--|---|-----------|
| 2.1. | Penelitian Terdahulu | 6 |
| 2.2. | <i>Artificial Intelligent</i> | 7 |
| 2.3. | <i>Forecasting</i> | 8 |
| 2.4. | <i>Deep Learning</i> | 9 |
| 2.5. | <i>Time series data</i> | 10 |
| 2.6. | Data Terstruktur | 10 |
| 2.7. | <i>Medical Information Mart for Intensive Care IV</i> | 10 |
| 2.8. | <i>Resample Data</i> | 11 |
| 2.9. | Imputasi Data | 12 |
| 2.10. | <i>Imbalance Data</i> | 13 |
| 2.10.1. | <i>Undersampling Data</i> | 14 |
| 2.10.2. | <i>Synthetic Minority Over-sampling Technique</i> | 15 |
| 2.11. | <i>Scalling Data</i> | 15 |
| 2.12. | <i>Gated Recurrent Unit</i> | 16 |
| 2.13. | <i>Long Short-Term Memory</i> | 17 |
| 2.14. | <i>Recurrent Neural Network</i> | 17 |
| 2.15. | <i>Convolutional Neural Network</i> | 18 |
| 2.16. | <i>Stacked Long Short-Term Memory</i> | 19 |
| 2.17. | <i>Bidirectional Long Short Term Memory</i> | 20 |
| 2.18. | <i>One-Dimensional Multi-Scale Network</i> | 21 |
| 2.19. | Pengukuran Kinerja | 22 |
| BAB III METODOLOGI PENELITIAN | | 25 |
| 3.1. | Kerangka Kerja | 25 |
| 3.2. | Ekstraksi Data | 27 |
| 3.3. | Pra-pemrosesan Data | 27 |
| 3.4. | <i>Data Splitting</i> | 31 |

| | |
|--|-----------|
| 3.5. Pelatihan Model | 34 |
| 3.6. <i>Model Evaluation</i> | 35 |
| BAB IV HASIL DAN ANALISIS | 36 |
| 4.1. Pendahuluan..... | 36 |
| 4.2. Hasil Pengujian pada Interval Data 24 Jam dengan Imputasi Interpolasi Linear, <i>Backward Fill</i> dan <i>Forward Fill</i> | 36 |
| 4.3. Peningkatan Akurasi Model dengan Data Imputasi Berbasis <i>Deep</i> <i>Learning</i> | 57 |
| 4.4. Analisis dan Perbandingan Hasil Pengujian | 72 |
| BAB V KESIMPULAN DAN SARAN | 75 |
| 5.1. Kesimpulan | 75 |
| 5.2. Saran | 75 |
| DAFTAR PUSTAKA | 77 |
| LAMPIRAN..... | 82 |

DAFTAR GAMBAR

| | |
|--|----|
| Gambar 2.1. Grafik Interpolasi Linear | 11 |
| Gambar 2.2. Arsitektur GRU | 16 |
| Gambar 2.3. Arsitektur LSTM | 17 |
| Gambar 2.4. Arsitektur RNN | 18 |
| Gambar 2.5. Arsitektur CNN | 19 |
| Gambar 2.6. Arsitektur <i>Stacked LSTM</i> | 20 |
| Gambar 2.7. Arsitektur BLSTM | 20 |
| Gambar 2. 8. Arsitektur 1D-MSNet | 21 |
| Gambar 3.1. Kerangka Kerja..... | 26 |
| Gambar 3.2. Fitur yang digunakan dalam penelitian | 27 |
| Gambar 3.3. Distribusi kelas target sebelum dan sesudah <i>undersampling</i> | 30 |
| Gambar 3.4. Distribusi kelas target sebelum dan sesudah dilakukan SMOTE..... | 31 |
| Gambar 3.5. Ilustrasi splitting data pada Penelitian dengan Metode GRU, LSTM, RNN, CNN, Bi-LSTM, dan Stacked LSTM | 32 |
| Gambar 3.6. Ilustrasi splitting data pada Penelitian dengan Metode 1D-MSNet . | 33 |
| Gambar 4.1. Grafik <i>Accuracy</i> dan <i>Loss</i> Model Terbaik dari Metode GRU, LSTM, RNN, CNN, Bi-LSTM, dan Stacked LSTM..... | 47 |
| Gambar 4. 2 <i>Confussion Matrix Data Training</i> dan <i>Validation</i> Pada Penelitian dengan Metode GRU, LSTM, RNN, CNN, Bi-LSTM, dan Stacked LSTM..... | 50 |
| Gambar 4.3. <i>Confussion Matrix Data Testing</i> pada Penelitian menggunakan Metode GRU, LSTM, RNN, CNN, Bi-LSTM, dan Stacked LSTM..... | 52 |
| Gambar 4.4. Grafik Perbandingan Akurasi Penelitian dengan Metode GRU, LSTM, RNN, CNN, Bi-LSTM, dan Stacked LSTM | 56 |
| Gambar 4.5. Grafik <i>accuracy</i> dan <i>loss</i> model terbaik dari setiap <i>Dataset</i> berdasarkan interval waktu | 61 |
| Gambar 4.6. Kurva ROC data <i>training</i> dan <i>validation</i> pada model terbaik setiap <i>Dataset</i> berdasarkan interval waktu | 63 |
| Gambar 4.7. Kurva ROC data <i>testing</i> pada model terbaik setiap <i>Dataset</i> berdasarkan interval waktu | 65 |
| Gambar 4.8. <i>Confusion matrix</i> data <i>training</i> dan <i>validation</i> pada model terbaik setiap <i>Dataset</i> berdasarkan interval waktu..... | 67 |

| | |
|--|----|
| Gambar 4. 9. <i>Confusion matrix</i> data <i>testing</i> pada model terbaik setiap <i>Dataset</i> berdasarkan interval waktu | 69 |
| Gambar 4.10 Grafik Perbandingan Akurasi pada Model terbaik..... | 71 |
| Gambar 4.11. Grafik Perbandingan Akurasi masing-masing Metode | 73 |

DAFTAR TABEL

| | |
|---|----|
| Tabel 2.1. Tabel <i>confussion matrix</i> | 22 |
| Tabel 4.1. Rangkuman Model yang digunakan dalam Pengujian dengan Metode GRU, LSTM, RNN, CNN, Bi-LSTM, dan Stacked LSTM..... | 37 |
| Tabel 4.2. Hasil Kinerja Model pada Data <i>Training</i> | 39 |
| Tabel 4.3. Hasil Kinerja Model pada Data <i>Validation</i> | 42 |
| Tabel 4.4. Perbandingan Hasil Evaluasi Kinerja Model Terbaik..... | 54 |
| Tabel 4.5. Rangkuman Hasil Pengujian data <i>Testing</i> | 55 |
| Tabel 4.6. Rangkuman Model yang digunakan dalam Pengujian Menggunakan Metode 1D-MSNet..... | 58 |
| Tabel 4.7. Rangkuman Kinerja Model Terbaik pada Data <i>Training</i> dan <i>Validation</i> | 58 |
| Tabel 4.8. Hasil Kinerja Model Terbaik pada Data <i>Testing</i> | 61 |
| Tabel 4.9. Ringkasan Pengujian Data <i>Training</i> , <i>Validation</i> , dan <i>testing</i> | 70 |
| Tabel 4.10. Perbandingan Hasil Penelitian Bi-LSTM dan 1D-MSNet..... | 72 |

BAB I

PENDAHULUAN

1.1. Latar Belakang

Pentingnya prediksi mortalitas pada pasien di unit perawatan intensif (ICU) tidak dapat diabaikan. Prediksi ini dapat membantu dalam perencanaan perawatan yang lebih baik, alokasi sumber daya yang efisien, dan pengambilan keputusan yang tepat waktu oleh tim medis. Dengan demikian, upaya untuk meningkatkan akurasi prediksi mortalitas memiliki dampak signifikan dalam meningkatkan kualitas perawatan di ICU.

Kemajuan dalam bidang *artificial intelligence* (AI) telah membuka pintu bagi inovasi signifikan di berbagai sektor, termasuk kesehatan. Teknologi AI untuk prediksi terus berkembang pesat, seperti halnya dalam prediksi mortalitas pada pasien unit perawatan intensif [1].

Penelitian terdahulu telah mengeksplorasi kemungkinan penerapan teknologi AI dalam prediksi mortalitas pada pasien unit perawatan intensif. Sebuah penelitian telah menunjukkan kemajuan signifikan dalam pengembangan algoritma berbasis *machine learning* untuk memprediksi mortalitas pasien dengan tingkat akurasi yang baik. Dalam penelitian [2] ini, dilakukan analisis retrospektif terhadap lebih dari 53.000 pasien ICU menggunakan *Dataset MIMIC*. Hasil penelitian menunjukkan bahwa prediktor XGBoost mampu menghasilkan nilai *area under the receiver operating characteristic curve* yang mengesankan, dengan tingkat prediksi mortalitas yang signifikan pada pasien-pasien yang menggunakan ventilator mekanis serta pasien-pasien yang terdiagnosis pneumonia dan COVID-19.

Berdasarkan kemajuan yang telah dicapai dalam penggunaan teknologi AI, dapat disadari bahwa masih ada potensi untuk peningkatan dalam prediksi pada data *time series multivariate*. Penerapan model *deep learning* dalam prediksi data *time series multivariate* telah menghasilkan peningkatan signifikan dalam akurasi prediksi, terutama berlaku ketika data input yang digunakan berkorelasi kuat dengan variabel target [3].

Selain itu, upaya untuk meningkatkan prediksi mortalitas juga berperan dalam mengoptimalkan perawatan intensif secara menyeluruh. Dengan menggunakan teknologi AI untuk memperkirakan hasil-hasil penting seperti mortalitas, perencanaan perawatan pasien dapat dilakukan dengan lebih terarah dan efisien, memungkinkan tim medis untuk fokus pada intervensi yang paling efektif dan tepat waktu. Hal ini dapat membantu mengurangi mortalitas pasien, meminimalkan komplikasi, dan mengoptimalkan penggunaan sumber daya di unit perawatan intensif.

Namun, pengembangan model prediksi yang akurat tidak terlepas dari tantangan. Salah satu tantangan utama adalah adanya 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 [4]. Oleh karena itu, teknik imputasi data menjadi sangat penting dalam proses pengolahan data, yang bertujuan untuk mengisi nilai yang hilang pada *Dataset* agar data yang digunakan dapat lebih akurat dan valid [5]. Selain nilai yang hilang, faktor lain yang berpengaruh pada penerapan model adalah ketidakseimbangan pada data. *Resampling* umum digunakan untuk menangani hal ini, keefektifannya pada *data time series* masih perlu dibuktikan [6]. Hasil penelitian menunjukkan bahwa *random undersampling* memberikan kinerja terbaik dengan model *deep neural network* untuk mendeteksi anomali dalam data *time series* yang tidak seimbang [6]. Dalam penelitian lainnya, *The Synthetic Minority Over-sampling Technique* terbukti menjadi teknik yang efisien untuk menangani data deret waktu yang tidak seimbang, meningkatkan kinerja model, dan mengurangi beban komputasi.

Dalam penelitian ini, metode *deep learning* dipilih sebagai pendekatan utama untuk memprediksi mortalitas pada pasien di unit perawatan intensif. *Deep learning* adalah cabang dari kecerdasan buatan yang menggunakan arsitektur jaringan saraf tiruan dengan banyak lapisan (*neuron*) untuk mempelajari pola kompleks dari data [7]. Beberapa pendekatan *deep learning* seperti *gated recurrent unit*, *long-short term memory*, *recurrent neural network*, *stacked long-short term memory*, *bidirectional long-short term memory*, dan *1-dimensional multiscale network* memiliki keunggulan dalam mengekstraksi fitur secara

otomatis dari data *time-series*, termasuk data medis yang kompleks. Berdasarkan beberapa penelitian yang telah dilakukan, membuktikan bahwa metode *deep learning* dapat meningkatkan akurasi model prediksi pada data. Oleh karena itu, dilakukan penelitian mengenai Prediksi Mortalitas pada Pasien Instalasi Perawatan Intensif Menggunakan *Deep Learning*. Penelitian ini bertujuan untuk mengidentifikasi model *deep learning* yang paling efektif dalam memprediksi hasil klinis di ICU. Dengan demikian, diharapkan dapat memberikan kontribusi signifikan dalam pengembangan alat prediktif yang lebih akurat dan andal untuk digunakan dalam praktik medis.

1.2. Perumusan Masalah

Berdasarkan pemaparan latar belakang dapat diuraikan perumusan masalah yaitu, meningkatkan akurasi prediksi mortalitas pada pasien ICU dengan memanfaatkan metode *deep learning*. Salah satu tantangan utama adalah bagaimana menangani nilai hilang dalam data *time-series multivariate* yang sering terjadi dalam *Dataset* rekam medis pasien. Selain itu, ketidakseimbangan kelas pada data *time-series multivariate* pasien ICU merupakan masalah serius yang dapat mempengaruhi kinerja model prediksi. Untuk mengatasi hal ini, penelitian ini mengembangkan model *deep learning* yang canggih dan menggunakan berbagai teknik untuk menangani nilai hilang serta mengatasi ketidakseimbangan kelas.

1.3. Batasan Masalah

Berdasarkan pemaparan latar belakang, maka dapat diuraikan perumusan masalah yang terdiri atas:

1. *Dataset* yang digunakan diambil dalam database MIMIC-IV berupa *Dataset time series multivariate* pada pasien unit perawatan intensif.
2. Menggunakan bahasa pemrograman python untuk pengolahan data dan membangun model prediksi.
3. Penelitian ini menggunakan metode *deep learning*.
4. Metrik evaluasi yang digunakan untuk mengukur kinerja model berupa akurasi, presisi, recall, dan F1-Score, dan nilai AUC.

1.4. Tujuan

Tujuan yang akan dicapai dari penelitian ini adalah sebagai berikut:

1. Mengembangkan model *deep learning* yang mampu meningkatkan akurasi prediksi mortalitas pada pasien di ICU.
2. Mengimplementasikan teknik yang efektif untuk mengatasi nilai yang hilang pada data *time-series multivariate*.
3. Mengimplementasikan teknik yang efektif untuk mengatasi ketidakseimbangan kelas pada data *time-series multivariate*.

1.5. Metodologi Penulisan

1.5.1. 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 “*Prediction Mortality with deep learning*”.

1.5.2. Metode Konsultasi

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

1.5.3. Metode Pembuatan Model

Metode ini membuat suatu perancangan pemodelan dengan menggunakan simulasi.

1.5.4. Metode Pengujian dan Validasi

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

1.5.5. Metode Hasil dan Analisa

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

1.5.6. 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.

1.6. Sistematika Penulisan

Sistematika yang digunakan dalam penulisan Tahap ini adalah :

BAB I PENDAHULUAN

Bab pertama akan memaparkan mengenai latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, serta sistematika penulisan yang digunakan.

BAB II TINJAUAN PUSTAKA

Bab ini akan memaparkan mengenai teori – teori dasar yang menjadi landasan dari penelitian yang dilakukan. Dasar teori yang dibahas pada bab ini adalah literatur mengenai mortalitas, imputasi data, model GRU, LSTM, dan RNN , dan performa validasi.

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

Bab ini akan menjelaskan hasil pengujian yang diperoleh dan menjelaskan analisa terhadap hasil penelitian yang telah dilakukan.

BAB V KESIMPULAN

Bab ini berisi kesimpulan dari hasil dan analisa dari keseluruhan penelitian yang dilakukan.

DAFTAR PUSTAKA

- [1] K. Pang, L. Li, W. Ouyang, X. Liu, and Y. Tang, "Establishment of ICU Mortality Risk Prediction Models with Machine Learning Algorithm Using MIMIC-IV Database," *Diagnostics*, vol. 12, no. 5, 2022, doi: 10.3390/diagnostics12051068.
- [2] L. Ryan *et al.*, "Mortality prediction model for the triage of COVID-19, pneumonia, and mechanically ventilated ICU patients: A retrospective study," *Ann. Med. Surg.*, vol. 59, no. July, pp. 207–216, 2020, doi: 10.1016/j.amsu.2020.09.044.
- [3] K. Park, Y. Jung, Y. Seong, and S. Lee, "Development of Deep Learning Models to Improve the Accuracy of Water Levels Time Series Prediction through Multivariate Hydrological Data," *Water (Switzerland)*, vol. 14, no. 3, 2022, doi: 10.3390/w14030469.
- [4] S. Nikfalazar, C. H. Yeh, S. Bedingfield, and H. A. Khorshidi, "Missing data imputation using decision trees and fuzzy clustering with iterative learning," *Knowl. Inf. Syst.*, vol. 62, no. 6, 2020, doi: 10.1007/s10115-019-01427-1.
- [5] M. R. A. Prasetya, A. M. Priyatno, and Nurhaeni, "Penanganan Imputasi Missing Values pada Data Time Series dengan Menggunakan Metode Data Mining," *J. Inf. dan Teknol.*, 2023, doi: 10.37034/jidt.v5i2.324.
- [6] M. Saripuddin, A. Suliman, and S. S. Sameon, "Impact of Resampling and Deep Learning to Detect Anomaly in Imbalance Time-Series Data," in *2022 IEEE 14th International Conference on Computer Research and Development, ICCRD 2022*, 2022. doi: 10.1109/ICCRD54409.2022.9730424.
- [7] M. Rizki, S. Basuki, and Y. Azhar, "Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory(LSTM) Untuk Prediksi Curah Hujan Kota Malang," *J. Repos.*, vol. 2, no. 3, 2020, doi: 10.22219/repositor.v2i3.470.

- [8] Y. Deng, S. Liu, Z. Wang, Y. Wang, Y. Jiang, and B. Liu, “Explainable time-series deep learning models for the prediction of mortality, prolonged length of stay and 30-day readmission in intensive care patients,” *Front. Med.*, vol. 9, no. September, pp. 1–11, 2022, doi: 10.3389/fmed.2022.933037.
- [9] J. Chen, T. Di Qi, J. Vu, and Y. Wen, “A deep learning approach for inpatient length of stay and mortality prediction,” *J. Biomed. Inform.*, vol. 147, no. October, p. 104526, 2023, doi: 10.1016/j.jbi.2023.104526.
- [10] 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,” *Journal of Energy Storage*, vol. 57, 2023. doi: 10.1016/j.est.2022.105978.
- [11] 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, 2022, doi: 10.1016/j.smhl.2022.100294.
- [12] 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, 2020, doi: 10.1007/s11739-019-02265-3.
- [13] 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, 2022, doi: 10.1016/j.scitotenv.2022.155070.
- [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.*, vol. 68, 2023, doi: 10.1016/j.jocs.2023.101984.
- [15] G. S. Chadha, A. Panambilly, A. Schwung, and S. X. Ding, “Bidirectional deep recurrent neural networks for process fault classification,” *ISA Trans.*, vol. 106, 2020, doi: 10.1016/j.isatra.2020.07.011.
- [16] 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.
- [17] 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.
- [18] R. Shwartz-Ziv and A. Armon, “Tabular data: Deep learning is not all you need,” *Inf. Fusion*, vol. 81, 2022, doi: 10.1016/j.inffus.2021.11.011.
- [19] M. Khushi *et al.*, “A Comparative Performance Analysis of Data Resampling Methods on Imbalance Medical Data,” *IEEE Access*, vol. 9, 2021, doi: 10.1109/ACCESS.2021.3102399.
- [20] I. Gede *et al.*, “Implementasi Metode Analytical Hierarchy Process Dan Interpolasi Linier Dalam Penentuan Lokasi Wisata Di Kabupaten Karangasem,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 5, no. 2, 2021.
- [21] D. Thera *et al.*, “Coding : Jurnal Komputer dan Aplikasi PENERAPAN METODE INTERPOLASI LINEAR DAN HISTOGRAM EQUALIZATION UNTUK PERBESARAN DAN PERBAIKAN CITRA,” *J. Komput. dan Apl.*, vol. 08, no. 01, pp. 1–10, 2020, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jcskommipa/article/view/39191>
- [22] Fahmi Dhimas Irnawan, Indriana Hidayah, and Lukito Edi Nugroho, “Metode Imputasi pada Data Debit Daerah Aliran Sungai Opak, Provinsi DI Yogyakarta,” *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 10, no. 4, 2021, doi: 10.22146/jnteti.v10i4.2430.
- [23] S. M. Ribeiro and C. L. Castro, “Missing Data in Time Series: A Review of Imputation Methods and Case Study,” *Learn. Nonlinear Model.*, vol. 20, no. 1, 2022, doi: 10.21528/lnlm-vol20-no1-art3.
- [24] M. Nguyen, T. He, L. An, D. C. Alexander, J. Feng, and B. T. T. Yeo, “Predicting Alzheimer’s disease progression using deep recurrent neural networks,” *Neuroimage*, vol. 222, 2020, doi: 10.1016/j.neuroimage.2020.117203.
- [25] F. Firdaus *et al.*, “XU-NetI: Simple U-Shaped Encoder-Decoder Network for Accurate Imputation of Multivariate Missing Data XU-NetI: Simple U-Shaped Encoder-Decoder Network for Accurate Imputation of Multivariate Missing Data XU-NetI: A Simple U-Shaped Encoder-Decoder Network ,” 2023, [Online]. Available: <https://doi.org/10.21203/rs.3.rs-3222386/v1>
- [26] C. Magnolia, A. Nurhopipah, and B. A. Kusuma, “Penanganan Imbalanced

- Dataset* untuk Klasifikasi Komentar Program Kampus Merdeka Pada Aplikasi Twitter,” *Edu Komputika J.*, vol. 9, no. 2, pp. 105–113, 2023, doi: 10.15294/edukomputika.v9i2.61854.
- [27] S. Choirunnisa, “Metode Hibrida Oversampling dan Undersampling Untuk Menangani Ketidakseimbangan Data Kegagalan Akademik Universitas XYZ,” 2019.
- [28] S. Mutmainah, “PENANGANAN IMBALANCE DATA PADA KLASIFIKASI KEMUNGKINAN PENYAKIT STROKE,” *J. Sains, Nalar, dan Apl. Teknol. Inf.*, vol. 1, no. 1, 2021.
- [29] J. Chen, T. Di Qi, J. Vu, and Y. Wen, “A deep learning approach for inpatient length of stay and mortality prediction,” *J. Biomed. Inform.*, vol. 147, no. June, p. 104526, 2023, doi: 10.1016/j.jbi.2023.104526.
- [30] Vika Vitaloka Pramansah, “Analisis Perbandingan Algoritma SVM Dan KNN Untuk Klasifikasi Anime Bergenre Drama,” *J. Inform. dan Teknol. Komput. (J-ICOM)*, vol. 3, no. 1, 2022, doi: 10.33059/j-icom.v3i1.4950.
- [31] W. Li, H. Wu, N. Zhu, Y. Jiang, J. Tan, and Y. Guo, “Prediction of dissolved oxygen in a fishery pond based on gated recurrent unit (GRU),” *Inf. Process. Agric.*, vol. 8, no. 1, pp. 185–193, 2021, doi: 10.1016/j.inpa.2020.02.002.
- [32] H. Abrishami, M. Campbell, and R. Czošek, “Supervised ECG Interval Segmentation Using LSTM Neural Network,” *Int. Conf. Bioinforma. Comput. Biol. BIOCAMP’18*, no. August, 2018.
- [33] A. Darmawahyuni *et al.*, “Deep learning with a recurrent network structure in the sequence modeling of imbalanced data for ECG-rhythm classifier,” *Algorithms*, vol. 12, no. 6, 2019, doi: 10.3390/a12060118.
- [34] “Erratum regarding previously published articles (Informatics in Medicine Unlocked (2020) 18, (S2352914819302230), (10.1016/j.imu.2019.100247)),” *Informatics in Medicine Unlocked*, vol. 20, 2020. doi: 10.1016/j.imu.2020.100436.
- [35] A. Hibatullah and I. Maliki, “Penerapan Metode Convolutional Neural Network Pada Pengenalan Pola Citra Sandi Rumput,” *J. Informatics Comput. Sci.*, vol. 1, no. 2, 2019.

- [36] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, 2020.
- [37] M. Diqi, S. Hasta Mulyani, U. Respati Yogyakarta, J. K. Laksda Adisucipto, and D. Sleman, "Enhancing Weather Prediction Using Stacked Long Short-Term Memory Networks," vol. 10, no. 3, 2023, [Online]. Available: <http://jurnal.mdp.ac.id>
- [38] 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.
- [39] M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani, and R. Budiarto, "Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking," *IEEE Access*, vol. 8, 2020, doi: 10.1109/ACCESS.2020.2994222.
- [40] 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, 2020, doi: 10.1016/B978-0-12-818366-3.00005-8.
- [41] J. Teknik *et al.*, "Volume 7, No 1, April 2022," vol. 7, no. 1, 2024.