

**PRAKIRAAN TANDA VITAL DARI DATA  
MULTIVARIATE TIME SERIES PASIEN UNIT  
PERAWATAN INTENSIF MENGGUNAKAN DEEP  
LEARNING**

**TUGAS AKHIR**

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



**OLEH :**  
**DIMAS ADITYA KRISTIANTO**  
**09011281823132**

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

**2022**

## LEMBAR PENGESAHAN

### PRAKIRAAN TANDA VITAL DARI DATA MULTIVARIATE TIME SERIES PASIEN UNIT PERAWATAN INTENSIF MENGGUNAKAN DEEP LEARNING

Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sistem Komputer

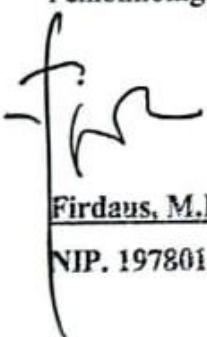
OLEH :

**DIMAS ADITYA KRISTIANTO**  
**09011281823132**

Indralaya, 31 Agustus 2022

Mengetahui,

Pembimbing Tugas Akhir 1

  
Firdaus, M.Kom.

NIP. 197801212008121003

Pembimbing Tugas Akhir 2

  
Sutarno, S.T., M.T.

NIP. 197811012010121003

Ketua Jurusan Sistem Komputer

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



## AUTHENTICATION PAGE

### FORECAST VITAL SIGNS FROM MULTIVARIATE TIME SERIES DATA OF INTENSIVE CARE UNIT PATIENTS USING DEEP LEARNING

#### FINAL TASK

Submitted to Complete One of the Conditions  
Obtaining Strata 1 Degree

By

Dimas Aditya Kristianto  
09011281823132

Indralaya, 3 Agustus 2022

Acknowledge,

Supervisor 1



Firdaus, M.Kom.  
NIP. 197801212008121003

Supervisor 2



Sutarno, S.T., M.T.  
NIP. 197811012010121003

Head of Computer System Department



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

## HALAMAN PERSETUJUAN

Telah diuji dan lulus pada:

Hari : Sabtu,  
Tanggal : 27 Agustus 2022

Tim Penguji :

1. Ketua : Dr. Ir. H. Sukemi M.T.

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

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

4. Pendamping I : Firdaus, M.Kom.

5. Pendamping II : Sutarno, M.T.

Mengetahui, *3/8/22*

Ketua Jurusan Sistem Komputer



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

## **HALAMAN PERNYATAAN**

Yang bertanda tangan di bawah ini :

Nama : Dimas Aditya Kristianto

NIM : 09011281823132

Judul : Prakiraan Tanda Vital Dari Data *Multivariate Time Series* Pasien Unit Perawatan Intensif Menggunakan *Deep Learning*

### **Hasil Pengecekan Software iThenticate/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.



**Indralaya, 31 Agustus 2022**

**Dimas Aditya Kristianto**  
**NIM.09011281823132**

## KATA PENGANTAR

Puji syukur kepada Allah Subhana Wata'ala atas dilancarkannya segala urusan sampai penulisan tugas akhir ini yang berjudul “**Prakiraan tanda vital dari data multivariate time series pasien unit perawatan intensif menggunakan deep learning**”.

Pada kesempatan ini, dengan segala kerendahan hati penulis mengucapkan terima kasih kepada semua pihak atas bantuan, bimbingan, dan saran yang telah diberikan dalam menyelesaikan Tugas Akhir ini, antara lain:

1. Allah Subhana Wata'ala yang telah memberikan berkah serta nikmat kesehatan dan kesempatan agar mampu menyelesaikan tugas akhir secara maksimal.
2. Orang tua tercinta, yaitu ibu saya Lestari dan ayah saya bapak Supriyono atas sagala cinta dan dukungannya dalam do'a.
3. Kakak-kakak saya, Singgih Taufika Setiawan, Ratih Puspita Sari, dan Nugraheni Ajeng Kusuma Astuti yang selalu menjadi penyemangat.
4. Bapak Firdaus, S.T, M.Kom. dan Bapak Sutarno, S.T., M.T, selaku Dosen Pembimbing Tugas Akhir yang telah berkenan meluangkan waktunya guna membimbing, memberikan saran dan motivasi serta bimbingan terbaik untuk penulis dalam menyelesaikan Tugas Akhir ini.
5. Kak Naufal, mbak Ade Iriani dan mbak Annisa selaku asisten Laboratorium *Intelligent Systems Research Group* (IsysRG) yang telah membimbing, memberikan saran, dan memotivasi untuk penulis dalam menyelesaikan Tugas Akhir ini.
6. Mbak Renny selaku admin Jurusan Sistem Komputer yang telah membantu mengurus seluruh berkas.
7. Kak qiliq yang telah membantu dalam format penulisan tugas akhir.
8. Muhammad Realdi, Muhammad Farhan Alharits, Ades Harafi Duri, Indah Cahya Resti, Alifah Fidela, Daffa Bima Perdana, Muhammad Furqon Rabbani, Prazna Paramitha Avi, Rani Oktaviani, Alif Almuqsit, Agung Al Hafizin, Jumhadi, Muhammad Imam Rafi,

Muhammad Taufik, Jepi Sujana, Dwi Lingga Hanayuda, dan M. Rafii Nanda W. yang telah memberi semangat.

9. Teman -teman se-angkatan jurusan sistem komputer yang telah memberi dukungan dan semangat dalam melalui masa perkuliahan.
10. Teman – teman di Laboratorium *Intelligent Systems Research Group* (IsysRG).
11. Dan semua pihak yang telah mendukung dan membantu.

Penulis menyadari bahwa tugas akhir ini masih sangat jauh dari kata sempurna. Untuk itu kritik dan saran yang membangun sangatlah diharapkan penulis. Akhir kata penulis berharap, semoga proposal tugas akhir ini bermanfaat dan berguna bagi khalayak.

Indralaya, 31 Agustus 2022

Penulis,



Dimas Aditya Kristianto  
NIM. 09011281823132

**FORECAST VITAL SIGNS FROM MULTIVARIATE TIME SERIES DATA  
OF INTENSIVE CARE UNIT PATIENTS USING DEEP LEARNING**

**DIMAS ADITYA KRISTIANTO (09011281823132)**

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

Email : [dimaskristianto1999@gmail.com](mailto:dimaskristianto1999@gmail.com)

**ABSTRACT**

*The vital signs recorded by the device at the patient's bedside are values commonly used in the medical field. Proper and accurate monitoring of vital signs is very important to ensure that the patient's health condition improves or worsens in the hospital. There are five vital signs often used: heartrate, blood pressure, oxygen saturation, respiratory rate, and body temperature. The use of vital signs as an indication of an event has been introduced in the medical industry more than a century ago. Even so, there is still a lot of research being done to improve the quality of clinical performance. The method used in this research is the deep learning method. The deep learning methods used are Long Short-Term Memory (LSTM) and Bidirectional Long Short-Term Memory (Bi-LSTM). In this study, the vital sign dataset used is a dataset taken from the MIMIC (Medical Information Mart for Intensive Care) database and then processed by making the data per window with one value from a predetermined forecast range. Each of these data, models will be built with various combinations of batch size and learning rate parameter settings so that they get good settings. The best model is the Bi-LSTM model with a batch size 16 parameter setting and a learning rate of 0.001 so that the RMSE value is 0.0171.*

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

**PRAKIRAAN TANDA VITAL DARI DATA MULTIVARIATE TIME  
SERIES PASIEN UNIT PERAWATAN INTENSIF MENGGUNAKAN  
DEEP LEARNING**

**DIMAS ADITYA KRISTIANTO (09011281823132)**

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

Email : [dimaskristianto1999@gmail.com](mailto:dimaskristianto1999@gmail.com)

**ABSTRAK**

Tanda-tanda vital yang direkam oleh perangkat di samping tempat tidur pasien adalah nilai yang biasa digunakan di bidang medis. Pemantauan tanda-tanda vital yang tepat dan akurat sangat penting untuk memastikan bahwa kondisi kesehatan pasien membaik atau memburuk di rumah sakit. Tanda vital sering digunakan ada lima, yaitu: denyut nadi, tekanan darah, saturasi oksigen darah, laju pernapasan, dan suhu tubuh. Penggunaan tanda vital sebagai indikasi suatu kejadian telah diperkenalkan di dunia industri medis lebih dari satu abad yang lalu. Meskipun begitu, masih banyak penelitian yang dibuat untuk meningkatkan kualitas performa secara klinis. Metode yang digunakan pada penelitian ini adalah metode *deep learning*. Metode *deep learning* yang digunakan adalah *Long Short-Term Memory* (LSTM) dan *Bidirectional Long Short-Term Memory* (Bi-LSTM). Pada penelitian ini dataset tanda vital yang digunakan adalah dataset yang diambil dari database MIMIC (*Medical Information Mart for Intensive Care*) kemudian akan diolah dengan cara membuat data nya berbentuk per jendela dengan satu nilai dari rentang prakira yang telah ditentukan. Masing-masing data tersebut akan dibangun model dengan berbagai kombinasi setelan parameter *batch size* dan *learning rate* sehingga mendapatkan setelan yang baik. Model terbaik merupakan model Bi-LSTM dengan setelan parameter batch size 16 dan learning rate 0.001 sehingga menghasilkan nilai nilai RMSE yaitu 0.0171.

**Kata Kunci** : Tanda vital, *Multivariate*, *Deep Learning*, *Long Short-Term Memory*, MIMIC Database

## DAFTAR ISI

<b>LEMBAR PENGESAHAN .....</b>	<b>II</b>
<b>AUTHENTICATION PAGE .....</b>	<b>III</b>
<b>HALAMAN PERSETUJUAN.....</b>	<b>IV</b>
<b>HALAMAN PERNYATAAN.....</b>	<b>V</b>
<b>KATA PENGANTAR.....</b>	<b>VI</b>
<b>ABSTRACT .....</b>	<b>VIII</b>
<b>ABSTRAK.....</b>	<b>IX</b>
<b>DAFTAR ISI .....</b>	<b>X</b>
<b>DAFTAR GAMBAR.....</b>	<b>XII</b>
<b>DAFTAR TABEL .....</b>	<b>XIII</b>
<b>BAB I. PENDAHULUAN .....</b>	<b>1</b>
1.1.    Latar Belakang .....	1
1.2.    Tujuan dan Manfaat .....	2
1.3.    Perumusan Masalah.....	3
1.4.    Batasan Masalah.....	3
1.5.    Metodologi Penelitian .....	4
1.5.1.    Metode Studi Pustaka dan Literatur .....	4
1.5.2.    Metode Konsultasi .....	4
1.5.3.    Metode Eksperimental.....	4
1.5.4.    Metode Penarikan Kesimpulan dan Saran .....	5
1.6.    Sistematika Penelitian .....	5
<b>BAB II. TINJAUAN PUSTAKA.....</b>	<b>7</b>
2.1    MIMIC-III .....	7
2.2    Tanda Vital ( <i>Vital Sign</i> ) .....	7
2.3    Time Series .....	8
2.4    Penskalaan.....	8
2.5    Pencilan.....	9
2.6    Imputing.....	9
2.7    Deep Learning.....	10
2.7.1    Recurrent Neural Network .....	10
2.7.2    Long-Short Term Memory (LSTM) .....	11
2.7.3    Bidirectional Long-Short Term Memory (BiLSTM).....	13
2.8    Regresi .....	14

2.9	Evaluasi model.....	14
2.9.1	Root Mean Squared Error (RMSE) .....	14
2.9.2	Mean Absolute Error (MAE) .....	15
<b>BAB III. METODOLOGI PENELITIAN.....</b>		<b>17</b>
3.1	Pendahuluan .....	17
3.2	Kerangka Kerja .....	17
3.3	Akuisisi Data.....	18
3.4	Data Pre-processing.....	19
3.4.1	Normalisasi Data.....	20
3.4.2	Tanda vital yang tak terekam .....	21
3.4.3	Pemisahan data.....	22
3.5	Imputing Data .....	22
3.6	Generate data.....	23
3.7	Pembagian data .....	26
3.8	Arsitektur .....	27
3.9	Fine Tuning .....	27
3.10	Evaluasi Model .....	28
<b>BAB IV HASIL DAN PEMBAHASAN.....</b>		<b>29</b>
4.1	Database MIMIC-III .....	29
4.2	Hasil Akuisisi Data .....	30
4.3	Pemilihan Data .....	31
4.3.1	Penciran.....	31
4.3.2	Filter Pasien .....	36
4.3.3	Pemisahan per rentetan data .....	36
4.4	Generate data.....	36
4.5	Evaluasi.....	37
<b>BAB V. KESIMPULAN .....</b>		<b>39</b>
5.1	Kesimpulan .....	39
5.2	Saran .....	39
<b>DAFTAR PUSTAKA.....</b>		<b>40</b>
<b>LAMPIRAN .....</b>		<b>45</b>

## DAFTAR GAMBAR

## DAFTAR TABEL

<b>Tabel 3. 1</b> Variasi data yang digunakan.....	27
<b>Tabel 4. 1</b> Total data dari setiap tabel di database MIMIC-III .....	29
<b>Tabel 4. 2</b> Rangkuman dataset tanda vital .....	30
<b>Tabel 4. 3</b> Total <i>time series data</i> pasien ICU irregular yang direkam.....	36
<b>Tabel 4. 4</b> Splitting dataset train, test, dan validasi .....	36
<b>Tabel 4. 5</b> Hasil RMSE masing-masing model.....	37
<b>Tabel lampiran 1</b> Rincian kode ICD9 yang digunakan untuk mengambil nilai tanda vital.....	45
<b>Tabel lampiran 2</b> Total data dari setiap pasien.....	46

# BAB 1.

## PENDAHULUAN

### 1.1. Latar Belakang

Pasien perawatan intensif di setiap rumah sakit selalu merekam tanda vital dari setiap pasien. Tanda vital seperti tingkat pernafasan, saturasi oksigen, tekanan darah, suhu tubuh, dan denyut nadi merupakan tanda vital yang bisa didapatkan dengan mudah namun memberikan informasi penting untuk memantau kondisi seseorang [1]. Pemantauan tanda-tanda vital pasien perawatan intensif sangat penting untuk memberikan perawatan yang tepat. Tanda vital digunakan sebagai acuan untuk mengetahui kejadian medis pada seorang pasien rumah sakit dimana sebagian besar kejadian ditandai dengan aktifitas tanda vital [1][2]. Penggunaan tanda vital sebagai indikasi suatu kejadian sudah diperkenalkan di dunia industri medis lebih dari satu abad yang lalu. Meskipun begitu, masih banyak penelitian yang dibuat untuk meningkatkan kualitas performa secara klinis. Metode prakira nilai tanda vital yang akan datang di bidang medis sudah banyak dikembangkan menggunakan *Machine Learning* (ML) [3]–[6]. Dengan mengetahui nilai tanda vital yang akan datang, para praktikal klinis dapat mempersiapkan tindakan lebih awal sebelum sesuatu terjadi. Namun pada penelitian ini, penulis akan menggunakan *Deep Learning* untuk membangun model prakira.

*Deep Learning* (DL) adalah jenis ML yang memiliki kemampuan untuk mempelajari data sekuensial yang abstrak. DL digunakan untuk mempelajari pola sekuensial. Meskipun DL memiliki kemampuan mempelajari pola data, DL masih memerlukan beberapa logika tambahan untuk membantu mengenali pola. Pada penelitian ini, penulis akan menggunakan arsitektur *Recurrent Neural Network*, *Long-Short Term Memory* dan *Bidirectional Long-Short Term Memory*. Arsitektur *Recurrent Neural Networks* (RNN) memiliki kemampuan untuk mengenali pola. Namun RNN memiliki kelemahan pada memori yang di-komputasi. *Long Short-Term Memory* (LSTM) mengatasi masalah tersebut dengan menambahkan gerbang *input*, *output*, dan *forget* [7]–[9]. LSTM memodelkan data sekuensial dengan panjang bervariasi, mencapai hasil mutakhir untuk masalah yang mencakup *natural language processing*, *image captioning*, *handwriting recognition*, dan *genomic*

*analysis*. LSTM. Pada penelitian sebelumnya [10]–[14], LSTM digunakan untuk memprakira nilai yang akan datang. Keuntungan dari arsitektur ini terletak di sifatnya yang membuat nilai lama akan kehilangan nilainya seiring berjalannya waktu. *Bidirectional Long-Short Term Memory* (BiLSTM) digunakan pada penelitian ini dikarenakan BiLSTM mempelajari data dengan dua arah. Dengan membandingkan lebih banyak metode, penulis dapat membandingkan semua metode yang digunakan untuk mendapatkan model arsitektur yang terbaik.

Untuk membuat model ML prakira, diperlukan tanda-tanda vital yang akan digunakan sebagai fitur untuk memprakirakan nilai tanda vital di masa depan[15]. Prapemrosesan yang akan dilakukan seperti *upscaleing*, interpolasi, dan pemotongan data diperlukan supaya model yang dihasilkan lebih bagus saat memasukkan dataset ke ML. Saat model berhasil dilatih, model akan dicoba untuk memprakira nilai tanda vital. Sebagai bahan perbandingan, nilai hasil prakira akan dibandingkan dengan nilai aktual dari dataset.

## 1.2. Tujuan dan Manfaat

### 1.2.1. Tujuan

Tujuan dari Tugas Akhir ini, yaitu:

1. Membangun model *Deep Learning* untuk memprakira nilai tanda vital pada pasien unit perawatan intensif.
2. Mencari seberapa banyak data dan rentang prakira yang digunakan untuk mendapatkan model *Deep Learning* terbaik.
3. Mencari metode prakiraan terbaik untuk prakiraan nilai tanda vital.

### 1.2.2. Manfaat

Manfaat dari penulisan Tugas Akhir ini, yaitu:

1. Dapat memberikan informasi tanda vital lebih dini dengan model prakira terbaik menggunakan sekumpulan data.

2. Dapat memberikan referensi jelas untuk penelitian mengenai prakiraan tanda vital di bidang medis kedepannya.

### **1.3. Perumusan Masalah**

Pada proses persiapan data, dilakukan tahap prapengolahan data menggunakan metode-metode yang disesuaikan sehingga mendapatkan dataset dan rentang prakira yang tepat untuk dimasukkan ke dalam arsitektur. Model arsitektur yang dihasilkan akan digunakan untuk menghasilkan nilai yang dapat dibandingkan dengan nilai yang dihasilkan oleh metode lainnya pada dataset yang digunakan. Sehingga hasil penelitian ini adalah metode yang ideal digunakan dari semua metode digunakan pada penelitian ini untuk mem-prakira nilai tanda vital

### **1.4. Batasan Masalah**

Batasan masalah pada penelitian tugas akhir ini adalah sebagai berikut:

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

## **1.5. Metodologi Penelitian**

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

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

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

### **1.5.2. Metode Konsultasi**

Pada bagian ini, penulis terlebih dahulu berkonsultasi dengan para dosen yang memiliki pengalaman dalam mengolah data dan membangun model prakira untuk menyelesaikan permasalahan penelitian ini.

### **1.5.3. Metode Eksperimental**

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

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

Hasil akhir dari pengerjaan tugas akhir dianalisis kualitas model yang telah dibangun dan seberapa lama waktu yang digunakan untuk model tersebut dilatih sehingga didapatkan model prakira yang bagus dan ideal untuk mem-prakira nilai tanda vital.

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

Metode terakhir yaitu mengambil kesimpulan dan memberi saran. untuk merangkum secara ringkas, padat dan jelas untuk membantu memberi informasi secara terstruktur dan baik, serta untuk memberi saran dan ide untuk penelitian kedepannya.

#### **1.6. Sistematika Penelitian**

Untuk memperjelas isi-isu dari tugas akhir, disusunlah sistematika penulisan seperti di bawah ini:

##### **BAB I PENDAHULUAN**

Pada bab pendahuluan akan diberi penjelasan secara rinci mengenai perihal latar belakang, tujuan, manfaat, perumusan dan batasan masalah, serta metodologi dan sistematika penelitian.

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

Pada bab tinjauan pustaka akan dijelaskan mengenai dasar teori dan materi-materi mengenai masalah yang akan diteliti dan penyelesaian dari penelitian yang digunakan dalam tugas akhir ini.

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

Pada bab metodologi penelitian akan dibahas secara rinci mengenai teknik, metode, dan alur proses yang dilakukan dalam penelitian untuk mendapatkan model yang ideal digunakan untuk memprakira nilai tanda vital.

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

Pada bab hasil dan analisis akan berisi mengenai hasil dan analisa yang didapat dari penggerjaan dan penelitian yang telah dikerjakan dari mekanisme yang digunakan.

**BAB V****KESIMPULAN**

Pada bab kesimpulan akan dibahas mengenai hasil penelitian secara ringkas, padat, dan jelas disertakan saran untuk penelitian selanjutnya khususnya tentang Tugas Akhir yang dikerjakan.

## DAFTAR PUSTAKA

- [1] J. Kellett and F. Sebat, “Make vital signs great again – A call for action,” *Eur. J. Intern. Med.*, vol. 45, pp. 13–19, 2017, doi: 10.1016/j.ejim.2017.09.018.
- [2] C. W. Seymour *et al.*, “Assessment of clinical criteria for sepsis for the third international consensus definitions for sepsis and septic shock (sepsis-3),” *JAMA - J. Am. Med. Assoc.*, vol. 315, no. 8, pp. 762–774, 2016, doi: 10.1001/jama.2016.0288.
- [3] S. C. Solomon *et al.*, “Forecasting a crisis: Machine-learning models predict occurrence of intraoperative bradycardia associated with hypotension,” *Anesth. Analg.*, vol. 130, no. 5, pp. 1201–1210, 2020, doi: 10.1213/ANE.0000000000004636.
- [4] O. Jacobson and H. Dalianis, “Applying deep learning on electronic health records in swedish to predict healthcare-associated infections,” *BioNLP 2016 - Proc. 15th Work. Biomed. Nat. Lang. Process.*, pp. 191–195, 2016, doi: 10.18653/v1/w16-2926.
- [5] R. Miotto, L. Li, B. A. Kidd, and J. T. Dudley, “Deep Patient: An Unsupervised Representation to Predict the Future of Patients from the Electronic Health Records,” *Sci. Rep.*, vol. 6, no. April, pp. 1–10, 2016, doi: 10.1038/srep26094.
- [6] M. Scherpf, F. Gräßer, H. Malberg, and S. Zaunseder, “Predicting sepsis with a recurrent neural network using the MIMIC III database,” *Comput. Biol. Med.*, vol. 113, no. August, 2019, doi: 10.1016/j.combiomed.2019.103395.
- [7] G. Petneházi, “Recurrent Neural Networks for Time Series Forecasting,” no. December 2018, 2018, [Online]. Available: <http://arxiv.org/abs/1901.00069>.

- [8] S. Elsworth and S. Güttel, “Time Series Forecasting Using LSTM Networks: A Symbolic Approach,” pp. 1–12, 2020, [Online]. Available: <http://arxiv.org/abs/2003.05672>.
- [9] G. Van Houdt, C. Mosquera, and G. Nápoles, “A review on the long short-term memory model,” *Artif. Intell. Rev.*, vol. 53, no. 8, pp. 5929–5955, 2020, doi: 10.1007/s10462-020-09838-1.
- [10] A. Y. A. Amer *et al.*, “Vital signs prediction and early warning score calculation based on continuous monitoring of hospitalised patients using wearable technology,” *Sensors (Switzerland)*, vol. 20, no. 22, pp. 1–21, 2020, doi: 10.3390/s20226593.
- [11] 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.
- [12] Y. Tian, K. Zhang, J. Li, X. Lin, and B. Yang, “LSTM-based traffic flow prediction with missing data,” *Neurocomputing*, vol. 318, pp. 297–305, 2018, doi: 10.1016/j.neucom.2018.08.067.
- [13] J. Ju and F. A. Liu, “Multivariate time series data prediction based on ATT-LSTM network,” *Appl. Sci.*, vol. 11, no. 20, 2021, doi: 10.3390/app11209373.
- [14] S. Liu, J. Yao, and M. Motani, “Early Prediction of Vital Signs Using Generative Boosting via LSTM Networks,” *Proc. - 2019 IEEE Int. Conf. Bioinforma. Biomed. BIBM 2019*, pp. 437–444, 2019, doi: 10.1109/BIBM47256.2019.8983313.
- [15] C. Esteban, O. Staech, S. Baier, Y. Yang, and V. Tresp, “Predicting Clinical Events by Combining Static and Dynamic Information Using Recurrent Neural Networks,” *Proc. - 2016 IEEE Int. Conf. Healthc. Informatics, ICHI 2016*, pp. 93–101, 2016, doi: 10.1109/ICHI.2016.16.

- [16] M. Scherpf, F. Gräßer, H. Malberg, and S. Zaunseder, “Predicting sepsis with a recurrent neural network using the MIMIC III database,” *Comput. Biol. Med.*, vol. 113, no. August, p. 103395, 2019, doi: 10.1016/j.combiomed.2019.103395.
- [17] R. Johnson, A., Pollard, T., & Mark, “MIMIC-III Clinical Database (version 1.4),” *Physionet*, 2016. <https://doi.org/10.13026/C2XW26>.
- [18] 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.
- [19] 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.
- [20] F. Dama and C. Sinoquet, “Time Series Analysis and Modeling to Forecast: a Survey,” pp. 1–76, 2021, [Online]. Available: <http://arxiv.org/abs/2104.00164>.
- [21] M. M. Ahsan, M. A. P. Mahmud, P. K. Saha, K. D. Gupta, and Z. Siddique, “Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance,” *Technologies*, vol. 9, no. 3, p. 52, 2021, doi: 10.3390/technologies9030052.
- [22] S. Džeroski, *Data Mining*. 2008.
- [23] A. Sherstinsky, “Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network,” *Phys. D Nonlinear Phenom.*, vol. 404, no. March, pp. 1–43, 2020, doi: 10.1016/j.physd.2019.132306.
- [24] 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, pp. 1–12, 2019, doi: 10.3390/a12060118.
- [25] Z. C. Lipton, D. C. Kale, C. Elkan, and R. Wetzel, “Learning to diagnose

- with LSTM recurrent neural networks,” *4th Int. Conf. Learn. Represent. ICLR 2016 - Conf. Track Proc.*, pp. 1–18, 2016.
- [26] A. Darmawahyuni, S. Nurmaini, and Sukemi, “Deep Learning with Long Short-Term Memory for Enhancement Myocardial Infarction Classification,” *Proc. 2019 6th Int. Conf. Instrumentation, Control. Autom. ICA 2019*, pp. 19–23, Jul. 2019, doi: 10.1109/ICA.2019.8916683.
  - [27] C. Chen, Z. Hua, R. Zhang, G. Liu, and W. Wen, “Automated arrhythmia classification based on a combination network of CNN and LSTM,” *Biomed. Signal Process. Control*, vol. 57, p. 101819, 2020, doi: 10.1016/j.bspc.2019.101819.
  - [28] S. L. Oh, E. Y. K. Ng, R. S. Tan, and U. R. Acharya, “Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats,” *Comput. Biol. Med.*, vol. 102, no. June, pp. 278–287, 2018, doi: 10.1016/j.combiomed.2018.06.002.
  - [29] S. Nurmaini *et al.*, “Electrocardiogram signal classification for automated delineation using bidirectional long short-term memory,” *Informatics Med. Unlocked*, vol. 22, p. 100507, 2021, doi: 10.1016/j.imu.2020.100507.
  - [30] A. Peimankar and S. Puthusserypady, “DENS-ECG: A deep learning approach for ECG signal delineation,” *Expert Syst. Appl.*, vol. 165, no. July 2020, p. 113911, 2021, doi: 10.1016/j.eswa.2020.113911.
  - [31] Y. Wang, Y. Du, J. Hu, X. Li, and X. Chen, “Saep: A surrounding-aware individual emotion prediction model combined with T-LSTM and memory attention mechanism,” *Appl. Sci.*, vol. 11, no. 23, 2021, doi: 10.3390/app112311111.
  - [32] P. Nguyen, T. Tran, and S. Venkatesh, “Deep learning to attend to risk in ICU,” *CEUR Workshop Proc.*, vol. 1891, pp. 25–29, 2017.
  - [33] D. Maulud and A. M. Abdulazeez, “A Review on Linear Regression Comprehensive in Machine Learning,” *J. Appl. Sci. Technol. Trends*, vol.

- 1, no. 4, pp. 140–147, 2020, doi: 10.38094/jastt1457.
- [34] A. Schneider, G. Hommel, and M. Blettner, “Lineare regressionsanalyse - Teil 14 der serie zur bewertung wissenschaftlicher publikationen,” *Dtsch. Arztebl.*, vol. 107, no. 44, pp. 776–782, 2010, doi: 10.3238/arztebl.2010.0776.
- [35] M. Saad, “Deep Learning Based Approaches for Imputation of Time Series Models by,” 2020.