

**OPTIMISASI PARAMETER RECURRENT NEURAL
NETWORK PADA PENDETEKSIAN ATRIAL
FIBRILLATION MENGGUNAKAN ALGORITMA
GRID SEARCH**

TUGAS AKHIR

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



OLEH:

**PUTRI WULANDARI
09011181722073**

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2021**

HALAMAN PENGESAHAN

OPTIMISASI PARAMETER RECURRENT NEURAL NETWORK PADA PENDETEKSIAN ATRIAL FIBRILLATION MENGGUNAKAN ALGORITMA GRID SEARCH

TUGAS AKHIR

**Program Studi Sistem Komputer
Jenjang S1**

**Oleh
PUTRI WULANDARI
09011181722073**

Indralaya, Juni 2021

Mengetahui,

Ketua Jurusan Sistem Komputer  **Pembimbing Tugas Akhir**

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



Prof. Dr. Ir. Siti Nurmaini, M.T.
NIP. 196908021994012001

HALAMAN PERSETUJUAN

Telah diuji dan lulus pada:

Hari : Selasa

Tanggal : 22 Juni 2021

Tim Penguji :

1. Ketua : Sutarno, M.T.

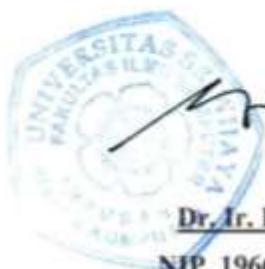
2. Sekretaris : Rendyansyah, M.T.

3. Penguji : Firdaus, M.Kom.

4. Pembimbing : Prof. Dr. Ir. Siti Nurmaini, M.T



Mengetahui, 5/6/24
Ketua Jurusan Sistem Komputer



Dr. Ir. H. Sukemi M.T.

NIP. 196612032006041001

HALAMAN PERNYATAAN

Yang bertanda tangan dibawah ini:

Nama : Putri Wulandari

NIM : 09011181722073

Judul : Optimisasi Parameter *Recurrent Neural Network* pada
Pendeteksian *Atrial Fibrillation* Menggunakan
Algoritma *Grid Search*

Hasil Pengecekan *Software iThenticate/Turnitin*: 11%

Menyatakan bahwa laporan tugas akhir saya merupakan hasil karya saya sendiri dan bukan hasil penjiplakan atau plagiat. Apabila ditemukan unsur penjiplakan atau plagiat dalam laporan ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya. Demikian, pernyataan ini saya buat dalam keadaan sadar dan tidak dipaksakan.



Indralaya, Juni 2021



Putri Wulandari

09011181722073

KATA PENGANTAR

Bismillahirrahmanirrahim.

Assalamu'alaikum Warahmatullahi Wabarakatuh.

Puji dan syukur penulis panjatkan kehadirat Allah SWT, karena berkat karunia dan rahmat-Nya sehingga penulis dapat menyelesaikan Tugas Akhir ini dengan judul "**Optimisasi Parameter Recurrent Neural Network pada Pendekstrian Atrial Fibrillation Menggunakan Algoritma Grid Search**".

Dalam laporan ini penulis menjelaskan mengenai optimisasi parameter pada model *Recurrent Neural Network* untuk mendekripsi penyakit *Atrial Fibrillation* dengan disertai data-data yang diperoleh penulis saat melakukan penelitian dan pengujian berbagai model. Penulis berharap agar tulisan ini dapat bermanfaat bagi orang banyak dan menjadi bahan bacaan bagi yang tertarik, terutama para peneliti yang berada di bidang medis dan elektrokardiogram.

Pada kesempatan ini penulis ingin mengucapkan terima kasih kepada beberapa pihak atas ide dan saran serta bantuannya dalam menyelesaikan penulisan Tugas Akhir ini. Oleh karena itu, pada kesempatan ini penulis mengucapkan rasa syukur dan terimakasih kepada yang terhormat:

1. Allah SWT, yang telah memberikan rahmat dan karunia-Nya sehingga proses penelitian dan penulisan Tugas Akhir ini dapat berjalan dengan lancar.
2. Kedua orang tua dan adik tercinta, yang selalu memberikan semangat dan do'a, serta dukungan baik moral, semangat, finansial maupun dukungan lainnya.
3. Bapak Jaidan Jauhari, S.Pd. M.T selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya
4. Bapak Dr. Ir. H. Sukemi, M.T. selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya dan juga Dosen Pembimbing Akademik di Jurusan Sistem Komputer yang selalu memberikan motivasi serta bimbingan selama proses perkuliahan.

5. Ibu Prof. Dr. Ir. Siti Nurmaini, M.T., selaku Dosen Pembimbing Tugas Akhir yang telah meluangkan waktunya untuk membimbing, memberikan saran dan motivasi serta bimbingan terbaik untuk penulis dalam menyelesaikan Tugas Akhir ini.
6. Bapak Firdaus, M.Kom., selaku Dosen Penguji Tugas Akhir yang selalu memberikan nasihat selama proses perkuliahan, pembelajaran, dan tugas akhir.
7. Mbak Annisa Darmawahyuni, M.Kom yang selalu memberikan bantuan, saran dan motivasi untuk penulis sehingga dapat menyelesaikan Tugas Akhir ini dengan baik.
8. Kak Naufal Rachmatullah, S.Kom., M.T., dan Mbak Ade Irian Safitri, M.Kom. yang telah memberikan semangat serta arahan kepada penulis sehingga dapat menyelesaikan Tugas Akhir ini dengan baik.
9. Kak Rahmi Khoirani yang telah membantu penulis dan juga memberikan semangat dalam proses penulisan Tugas Akhir.
10. Jannes Effendi yang telah memberikan bantuan serta semangat untuk penulis dari awal hingga akhir proses penelitian dan penulisan Tugas Akhir.
11. Alna Yopa Khotimah selaku teman seperjuangan selama penggerjaan Tugas Akhir yang telah memberikan motivasi, semangat, dan dukungan selama proses penelitian dan penulisan Tugas Akhir.
12. Suci Dwi Lestari, Annisa Karima R. Harahap, Ghina Auliya, Abdullah Farhan, dan Arjuno Gusendi yang selalu memberikan bantuan dan juga semangat selama proses pengekerjaan Tugas Akhir.
13. Tim sinyal ISYSRG Batch 2 yang selalu memberikan bantuan, semangat, dan motivasi kepada penulis selama proses penelitian dan penulisan Tugas Akhir.
14. Teman-teman seperjuangan di Intelligent System Research Group yang selalu menyemangati satu sama lain dan saling membantu agar dapat menyelesaikan Tugas Akhir ini.
15. Teman-teman Sistem Komputer terutama angkatan 2017 yang selalu memberikan dukungan semangat sehingga penulis dapat menyelesaikan Tugas Akhir ini.

Penulis juga berterima kasih kepada semua pihak yang terlibat, baik secara langsung ataupun tidak langsung dalam penyelesaian Tugas Akhir ini. Penulis menyadari bahwa Laporan ini masih jauh dari kesempurnaan, oleh karena itu penulis sangat mengharapkan kritik dan saran yang bersifat membangun agar lebih baik lagi dikemudian hari.

Akhir kata dengan segala keterbatasan, penulis berharap semoga laporan ini menghasilkan sesuatu yang bermanfaat bagi kita semua khususnya bagi mahasiswa Fakultas Ilmu Komputer Universitas Sriwijaya secara langsung ataupun tidak langsung sebagai sumbangan pikiran dalam peningkatan mutu pembelajaran dan penelitian.

Indralaya, Juni 2021
Penulis,

Putri Wulandari
NIM. 09011181722073

**OPTIMIZATION OF RECURRENT NEURAL NETWORK
PARAMETER IN ATRIAL FIBRILLATION DETECTION USING
GRID SEARCH ALGORITHM**

PUTRI WULANDARI (09011181722073)

*Computer Engineering Department, Computer Science Faculty, Sriwijaya
University*
Email: wulandaripri41@gmail.com

ABSTRACT

Atrial fibrillation (AF) is an abnormality in the rhythm of the human heartbeat that can cause stroke and heart failure. The process of detecting this disease is done by looking at and analyzing the morphology of the Electrocardiogram (ECG). This research uses the Deep Learning method because it can maximize the use of all information that comes from input, so that the decisions taken are stronger and better. For times series data, the Recurrent Neural Network (RNN) method is suitable for use. The types of RNN used are Long Short-Term Memory (LSTM), Bidirectional Long Short-Term Memory (BiLSTM) and also Gated Recurrent Unit (GRU) because they can overcome the vanishing gradient problem in RNN. There are two cases in this study, namely the use of imbalance data and balance data. The parameter tuning process used Grid Search algorithm by combining parameters such as learning rate, batch size and epoch to found the best model. The best model from each classifier will be tried again by adding a feature extraction process used Convolutional Neural Network (CNN). Based on the experimental results, the model that used the CNN feature extraction process has better results than the model without the feature extraction process. The model that has the best results was CNN-GRU model for data imbalance and data balance. On the imbalance data, the accuracy, sensitivity, specificity, precision, and F1 scores respectively 97.19%, 98.83%, 85.47%, 97.97% and 98.4%. On the balance data, the accuracy, sensitivity, specificity, precision, and F1 scores respectively 93.71%, 91.48%, 96.09%, 96.16%, and 93.76%.

Keywords: Atrial Fibrillation, Electrocardiogram, Detection, Long Short-Term Memory, Bidirectional Long Short-Term Memory, Gated Recurrent Unit, Convolutional Neural Network, Grid Search.

OPTIMISASI PARAMETER *RECURRENT NEURAL NETWORK* PADA PENDETEKSIAN *ATRIAL FIBRILLATION* MENGGUNAKAN ALGORITMA *GRID SEARCH*

PUTRI WULANDARI (09011181722073)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya
Email: wulandaripri41@gmail.com

ABSTRAK

Atrial Fibrillation (AF) adalah kelainan pada irama detak jantung manusia yang dapat menyebabkan penyakit stroke bahkan penyakit gagal jantung. Proses deteksi penyakit ini dilakukan dengan melihat dan menganalisa morfologi Elektrokardiogram (EKG). Penelitian kali ini menggunakan metode *Deep Learning* karena dapat memaksimalkan penggunaan semua informasi yang berasal input, sehingga keputusan yang diambil menjadi lebih kuat dan baik. Untuk data yang bersifat *times series*, metode *Recurrent Neural Network* (RNN) cocok untuk digunakan. Adapun jenis RNN yang digunakan adalah *Long Short-Term Memory* (LSTM), *Bidirectional Long Short-Term Memory* (BiLSTM) dan juga *Gated Recurrent Unit* (GRU) dikarenakan dapat mengatasi masalah *vanishing gradient* pada RNN. Terdapat dua case dalam penelitian kali ini yaitu penggunaan *data imbalance* dan juga *data balance*. Proses tuning parameter untuk menemukan model terbaik dilakukan dengan menggunakan algoritma *Grid Search* dengan mengombinasikan parameter seperti learning rate, batch size dan epoch. Model terbaik dari masing-masing *classifier* akan dicoba kembali dengan menambahkan proses fitur ekstraksi menggunakan *Convolutional Neural Network* (CNN). Berdasarkan hasil percobaan, model yang menggunakan proses fitur ekstraksi CNN memiliki hasil yang lebih baik dibandingkan dengan model tanpa proses fitur ekstraksi. Model yang memiliki hasil terbaik adalah model CNN-GRU untuk data imbalance dan data balance. Pada data imbalance, nilai akurasi, sensitivitas, spesifisitas, presisi, dan F1 score masing-masing adalah 97,19%, 98,83%, 85,47%, 97,97% dan 98,4%. Sedangkan pada data balance, nilai akurasi, sensitivitas, spesifisitas, presisi, dan F1 score masing-masing adalah 93,71%, 91,48%, 96,09%, 96,16%, dan 93,76%.

Kata Kunci: *Atrial Fibrillation*, Elektrokardiogram, Deteksi, *Long Short-Term Memory*, *Bidirectional Long Short-Term Memory*, *Gated Recurrent Unit*, *Convolutional Neural Network*, *Grid Search*.

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
HALAMAN PENGESAHAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR	v
ABSTRACT	viii
ABSTRAK	ix
DAFTAR ISI	x
DAFTAR GAMBAR	xv
DAFTAR TABEL	xix
DAFTAR LAMPIRAN	xxv
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Tujuan dan Manfaat.....	2
1.2.1 Tujuan.....	2
1.2.2 Manfaat.....	3
1.3 Perumusan dan Batasan Masalah.....	3
1.3.1 Perumusan Masalah.....	3
1.3.2 Batasan Masalah.....	3
1.4 Metodologi Penelitian.....	3
1.4.1 Tahap Pertama (Persiapan Data).....	3
1.4.2 Tahap Kedua (Pra Pengolahan Data).....	3
1.4.3 Tahap Ketiga (Membagi Data Latih dan Data Uji).....	4
1.4.4 Tahap Keempat (Perancangan Model).....	4
1.4.5 Tahap Kelima (Tuning Parameter, Pengujian dan Validasi Hasil).....	4
1.4.6 Tahap Keenam (Analisa dan Kesimpulan).....	4

1.5	Sistematika Penulisan	4
BAB II	TINJAUAN PUSTAKA	6
2.1	<i>Atrial Fibrillation</i>	6
2.2	Elektrokardiogram	6
2.3	<i>Discrete Wavelet Transform</i>	8
2.4	<i>Deep Learning</i>	10
2.5	<i>Recurrent Neural Network</i>	11
2.5.1	<i>Long Short-Term Memory</i>	11
2.5.2	<i>Bidirectional Long Short-Term Memory</i>	13
2.5.3	<i>Gated Recurrent Unit</i>	14
2.6	<i>Grid Search</i>	15
2.7	Validasi Performa	15
2.7.1	Akurasi	16
2.7.2	Sensitivitas	16
2.7.3	Spesifisitas	16
2.7.4	Presisi	17
2.7.5	F1-Score	17
BAB III	METODOLOGI	18
3.1	Pendahuluan	18
3.2	Kerangka Kerja	18
3.3	Persiapan Data	19
3.4	Pra-Pengolahan Data	22
3.4.1	Penghilangan Derau Sinyal	22
3.4.2	Normalisasi	23
3.4.3	Segmentasi	23
3.4.4	<i>Under-sampling</i>	24
3.5	Pembagian Data Latih dan Data Uji	26
3.6	Perancangan Model <i>Recurrent Neural Network</i> (RNN) Untuk Deteksi <i>Atrial Fibrillation</i>	27

3.6.1	Model <i>Long Short-Term Memory</i> (LSTM).....	27
3.6.2	Model <i>Bidirectional Long Short-Term Memory</i> (BiLSTM).....	29
3.6.3	Model <i>Gated Recurrent Unit</i> (GRU).....	29
3.7	Tuning Parameter.....	30
3.8	Validasi Performa Model.....	33
BAB IV	HASIL DAN ANALISA.....	34
4.1	Pendahuluan.....	34
4.2	Hasil Pra-pengolahan Sinyal.....	34
4.2.1	Hasil Penghilangan Derau Sinyal.....	34
4.2.2	Hasil Normalisasi.....	37
4.2.3	Hasil Segmentasi.....	38
4.3	Hasil Tuning Parameter.....	38
4.4	Hasil Deteksi Menggunakan Model 60.....	41
4.4.1	<i>Case Data Imbalance</i>	42
4.4.2	<i>Case Data Balance</i>	43
4.5	Hasil Deteksi Menggunakan Model 40.....	45
4.5.1	<i>Case Data Imbalance</i>	45
4.5.2	<i>Case Data Balance</i>	47
4.6	Hasil Deteksi Menggunakan Model 5.....	49
4.6.1	<i>Case Data Imbalance</i>	49
4.6.2	<i>Case Data Balance</i>	51
4.7	Model Terbaik Untuk Masing-Masing Algoritma Klasifikasi pada <i>Data Imbalance</i>	52
4.7.1	Model <i>Long Short-Term Memory</i> (LSTM) Terbaik	53
4.7.2	Model <i>Bidirectional Long Short-Term Memory</i> (BiLSTM) Terbaik	56
4.7.3	Model <i>Gated Recurrent Unit</i> (GRU) Terbaik	59

4.7.4	Model <i>Convolutional Neural Network Long Short-Term Memory</i> (CNN-LSTM) Terbaik.....	62
4.7.5	Model <i>Convolutional Neural Network Bidirectional Long Short-Term Memory</i> (CNN-BiLSTM) Terbaik.....	65
4.7.6	Model <i>Convolutional Neural Network Gated Recurrent Unit</i> (CNN-GRU) Terbaik.....	68
4.8	Model Terbaik Untuk Masing-Masing Algoritma Klasifikasi pada <i>Data Balance</i>	71
4.8.1	Model <i>Long Short-Term Memory</i> (LSTM) Terbaik	71
4.8.2	Model <i>Bidirectional Long Short-Term Memory</i> (BiLSTM) Terbaik.....	74
4.8.3	Model <i>Gated Recurrent Unit</i> (GRU) Terbaik.....	77
4.8.4	Model <i>Convolutional Neural Network Long Short-Term Memory</i> (CNN-LSTM) Terbaik.....	80
4.8.5	Model <i>Convolutional Neural Network Bidirectional Long Short-Term Memory</i> (CNN-BiLSTM) Terbaik.....	83
4.8.6	Model <i>Convolutional Neural Network Gated Recurrent Unit</i> (CNN-GRU) Terbaik.....	86
4.9	Perbandingan Hasil Pengujian Ketiga Model Terbaik dengan Menggunakan Berbagai Macam Algoritma Klasifikasi.....	89
4.10	Perbandingan Hasil Evaluasi Pengujian Model dari Setiap Algoritma Klasifikasi.....	98
4.11	Analisa.....	102

BAB V	KESIMPULAN DAN SARAN.....	104
5.1	Pendahuluan.....	104
5.2	Kesimpulan.....	104
5.3.	Saran.....	106
DAFTAR PUSTAKA.....		106

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Sinyal Elektrokardiogram Normal[1].....	7
Gambar 2.2 Model Dekomposisi Low Pass Filter dan High Pass Filter [2].....	8
Gambar 2.3 Beberapa Mother wavelet DWT [3].....	10
Gambar 2.4 Gate pada Blok LSTM [4].....	12
Gambar 2.5 Struktur <i>bidirectional</i> LSTM pada (a) <i>forward pass</i> dan (b) <i>backward pass</i> [5].....	13
Gambar 2.6 Model Satuan Sel GRU [6].....	14
Gambar 3.1 Kerangka Kerja (a) <i>Case Imbalance</i> (b) <i>Case Balance</i>	19
Gambar 3.2 Morfologi Sinyal Normal pada Data <i>PhysioNet/CinC Challenge</i> 2017	21
Gambar 3.3 Morfologi Sinyal AF pada Data <i>PhysioNet/CinC Challenge</i> 2017	21
Gambar 3.4 Perbandingan Jumlah Data Setiap Kelas Sebelum <i>Under-sampling</i>	25
Gambar 3.5 Perbandingan Jumlah Data Setiap Kelas Setelah <i>Under-sampling</i>	26
Gambar 3.6 Perbandingan Data Latih dan Data Uji pada <i>Splitting Data</i>	27
Gambar 4.1 Rekonstruksi Sinyal Menggunakan <i>Mother Wavelet db2</i>	35
Gambar 4.2 Rekonstruksi Sinyal Menggunakan <i>Mother Wavelet sym5</i>	36
Gambar 4.3 Perbandingan Sinyal Normal Sebelum dan Sesudah DWT	36
Gambar 4.4 Perbandingan Sinyal AF Sebelum dan Sesudah DWT	37
Gambar 4.5 Perbandingan Sinyal Normal Sebelum dan Sesudah Normalisasi	37
Gambar 4.6 Perbandingan Sinyal AF Sebelum dan Sesudah Normalisasi	37
Gambar 4.7 Perbandingan Sinyal Normal Sebelum dan Sesudah Segmentasi	38
Gambar 4.8 Perbandingan Sinyal AF Sebelum dan Sesudah Segmentasi	38

Gambar 4.9 Grafik Akurasi dan Loss Model 60 <i>Data Imbalance</i>	42
Gambar 4.10 Grafik Akurasi dan Loss Model 60 <i>Data Balance</i>	43
Gambar 4.11 Grafik Akurasi dan Loss Model 40 <i>Data Imbalance</i>	45
Gambar 4.12 Grafik Akurasi dan Loss Model 40 <i>Data Balance</i>	47
Gambar 4.13 Grafik Akurasi dan Loss Model 5 <i>Data Imbalance</i>	49
Gambar 4.14 Grafik Akurasi dan Loss Model 5 <i>Data Balance</i>	51
Gambar 4.15 Grafik Perbandingan Akurasi dan Loss Model LSTM Terbaik (<i>Data Imbalance</i>)	54
Gambar 4.16 Kurva ROC Model LSTM Terbaik (<i>Data Imbalance</i>)	56
Gambar 4.17 Grafik Perbandingan Akurasi dan Loss Model BiLSTM Terbaik (<i>Data Imbalance</i>)	57
Gambar 4.18 Kurva ROC Model BiLSTM Terbaik (<i>Data Imbalance</i>)	59
Gambar 4.19 Grafik Perbandingan Akurasi dan Loss Model GRU Terbaik (<i>Data Imbalance</i>)	60
Gambar 4.20 Kurva ROC Model GRU Terbaik (<i>Data Imbalance</i>)	62
Gambar 4.21 Grafik Perbandingan Akurasi dan Loss Model CNN-LSTM Terbaik (<i>Data Imbalance</i>)	63
Gambar 4.22 Kurva ROC Model CNN-LSTM Terbaik (<i>Data Imbalance</i>)	65
Gambar 4.23 Grafik Perbandingan Akurasi dan Loss Model CNN-BiLSTM Terbaik (<i>Data Imbalance</i>)	66
Gambar 4.24 Kurva ROC Model CNN-BiLSTM Terbaik (<i>Data Imbalance</i>)	68
Gambar 4.25 Grafik Perbandingan Akurasi dan Loss Model CNN-GRU Terbaik (<i>Data Imbalance</i>)	69
Gambar 4.26 Kurva ROC Model CNN-GRU Terbaik (<i>Data Imbalance</i>)	70
Gambar 4.27 Grafik Perbandingan Akurasi dan Loss Model LSTM Terbaik (<i>Data Balance</i>)	72
Gambar 4.28 Kurva ROC Model LSTM Terbaik (<i>Data Balance</i>)	74
Gambar 4.29 Grafik Perbandingan Akurasi dan Loss Model BiLSTM Terbaik (<i>Data Balance</i>)	75
Gambar 4.30 Kurva ROC Model BiLSTM Terbaik (<i>Data Balance</i>)	77

Gambar 4.31 Grafik Perbandingan Akurasi dan Loss Model GRU Terbaik (<i>Data Balance</i>)	78
Gambar 4.32 Kurva ROC Model GRU Terbaik (<i>Data Balance</i>)	80
Gambar 4.33 Grafik Perbandingan Akurasi dan Loss Model CNN-LSTM Terbaik (<i>Data Balance</i>)	81
Gambar 4.34 Kurva ROC Model CNN-LSTM Terbaik (<i>Data Balance</i>)	83
Gambar 4.35 Grafik Perbandingan Akurasi dan Loss Model CNN-BiLSTM Terbaik (<i>Data Balance</i>)	84
Gambar 4.36 Kurva ROC Model CNN-BiLSTM Terbaik (<i>Data Balance</i>)	86
Gambar 4.37 Grafik Perbandingan Akurasi dan Loss Model CNN-GRU Terbaik (<i>Data Balance</i>)	87
Gambar 4.38 Kurva ROC Model CNN-GRU Terbaik (<i>Data Balance</i>)	89
Gambar 4.39 Perbandingan Evaluasi Pengujian pada Model LSTM (<i>Data Imbalance</i>)	91
Gambar 4.40 Perbandingan Evaluasi Pengujian pada Model BiLSTM (<i>Data Imbalance</i>)	91
Gambar 4.41 Perbandingan Evaluasi Pengujian pada Model GRU (<i>Data Imbalance</i>)	92
Gambar 4.42 Perbandingan Evaluasi Pengujian pada Model CNN-LSTM (<i>Data Imbalance</i>)	92
Gambar 4.43 Perbandingan Evaluasi Pengujian pada Model CNN-BiLSTM (<i>Data Imbalance</i>)	93
Gambar 4.44 Perbandingan Evaluasi Pengujian pada Model CNN-GRU (<i>Data Imbalance</i>)	93
Gambar 4.45 Perbandingan Evaluasi Pengujian pada Model LSTM (<i>Data Balance</i>)	95
Gambar 4.46 Perbandingan Evaluasi Pengujian pada Model BiLSTM (<i>Data Balance</i>)	96
Gambar 4.47 Perbandingan Evaluasi Pengujian pada Model GRU (<i>Data Balance</i>)	96
Gambar 4.48 Perbandingan Evaluasi Pengujian pada Model CNN-LSTM	

(<i>Data Balance</i>).....	97
Gambar 4.49 Perbandingan Evaluasi Pengujian pada Model CNN-BiLSTM (<i>Data Balance</i>).....	97
Gambar 4.50 Perbandingan Evaluasi Pengujian pada Model LSTM (<i>Data Balance</i>).....	98
Gambar 4.51 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi RNN (<i>Data Imbalance</i>).....	99
Gambar 4.51 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi CNN-RNN (<i>Data Imbalance</i>).....	100
Gambar 4.53 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi RNN (<i>Data Balance</i>).....	101
Gambar 4.54 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi CNN-RNN (<i>Data Balance</i>).....	101

DAFTAR TABEL

	Halaman
Tabel 2.1 Contoh Matriks Konfusi Dua Kelas.....	16
Tabel 3.1 Jumlah Masing-Masing Kelas Dataset <i>PhysioNet/CinC Challenge 2017</i>	20
Tabel 3.2 Pembagian Jumlah Dataset Kelompok Kelas Baru.....	20
Tabel 3.3 Jumlah Data Sinyal Setiap Kelas.....	24
Tabel 3.4 Jumlah Data Setiap Kelas Hasil <i>Under-sampling</i>	26
Tabel 3.5 Perbandingan Data Latih dan Data Uji Pada <i>Data Imbalance</i>	27
Tabel 3.6 Perbandingan Data Latih dan Data Uji Pada <i>Data Balance</i>	27
Tabel 3.7 Parameter Umum Model LSTM.....	28
Tabel 3.8 Parameter Umum Model BiLSTM.....	29
Tabel 3.9 Parameter Umum Model GRU.....	30
Tabel 3.10 Rincian Parameter yang Akan Dituning.....	31
Tabel 3.11 Rincian Model Hasil Kombinasi Parameter yang Akan Dituning.....	31
Tabel 4.1 Nilai SNR dari Setiap <i>Mother Wavelet</i>	34
Tabel 4.2 Hasil Tuning Parameter LSTM Menggunakan Algoritma <i>Grid Search</i>	39
Tabel 4.3 Matriks Konfusi Data Pelatihan Model 60 (<i>Data Imbalance</i>).....	42
Tabel 4.4 Matriks Konfusi Data Pengujian Model 60 (<i>Data Imbalance</i>).....	42
Tabel 4.5 Evaluasi Performa Data Pelatihan Model 60 (<i>Data Imbalance</i>).....	43
Tabel 4.6 Evaluasi Performa Data Pengujian Model 60 (<i>Data Imbalance</i>).....	43
Tabel 4.7 Matriks Konfusi Data Pelatihan Model 60 (<i>Data Balance</i>).....	44
Tabel 4.8 Matriks Konfusi Data Pengujian Model 60 (<i>Data Balance</i>).....	44
Tabel 4.9 Evaluasi Performa Data Pelatihan Model 60 (<i>Data Balance</i>).....	44
Tabel 4.10 Evaluasi Performa Data Pengujian Model 60 (<i>Data Balance</i>).....	45
Tabel 4.11 Matriks Konfusi Data Pelatihan Model 40 (<i>Data Imbalance</i>).....	46
Tabel 4.12 Matriks Konfusi Data Pengujian Model 40 (<i>Data Imbalance</i>).....	46
Tabel 4.13 Evaluasi Performa Data Pelatihan Model 40 (<i>Data Imbalance</i>).....	46
Tabel 4.14 Evaluasi Performa Data Pengujian Model 40 (<i>Data Imbalance</i>).....	46
Tabel 4.15 Matriks Konfusi Data Pelatihan Model 40 (<i>Data Balance</i>).....	47

Tabel 4.16 Matriks Konfusi Data Pengujian Model 40 (<i>Data Balance</i>)	48
Tabel 4.17 Evaluasi Performa Data Pelatihan Model 40 (<i>Data Balance</i>)	48
Tabel 4.18 Evaluasi Performa Data Pengujian Model 40 (<i>Data Balance</i>)	48
Tabel 4.19 Matriks Konfusi Data Pelatihan Model 5 (<i>Data Imbalance</i>)	49
Tabel 4.20 Matriks Konfusi Data Pengujian Model 5 (<i>Data Imbalance</i>)	50
Tabel 4.21 Evaluasi Performa Data Pelatihan Model 5 (<i>Data Imbalance</i>)	50
Tabel 4.22 Evaluasi Performa Data Pengujian Model Terbaik 5 (<i>Data Imbalance</i>)	50
Tabel 4.23 Matriks Konfusi Data Pelatihan Model 5 (<i>Data Balance</i>)	51
Tabel 4.24 Matriks Konfusi Data Pengujian Model 5(<i>Data Balance</i>)	51
Tabel 4.25 Evaluasi Performa Data Pelatihan Model 5 (<i>Data Balance</i>)	52
Tabel 4.26 Evaluasi Performa Data Pengujian Model 5 (<i>Data Balance</i>)	52
Tabel 4.27 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi LSTM	53
Tabel 4.28 Matriks Konfusi Data Pelatihan Model LSTM Terbaik (<i>Data Imbalance</i>)	54
Tabel 4.29 Matriks Konfusi Data Pengujian Model LSTM Terbaik (<i>Data Imbalance</i>)	54
Tabel 4.30 Evaluasi Performa Data Pelatihan Model LSTM Terbaik (<i>Data Imbalance</i>)	55
Tabel 4.31 Evaluasi Performa Data Pengujian Model LSTM Terbaik (<i>Data Imbalance</i>)	55
Tabel 4.32 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi BiLSTM (<i>Data Imbalance</i>)	56
Tabel 4.33 Matriks Konfusi Data Pelatihan Model BiLSTM Terbaik (<i>Data Imbalance</i>)	57
Tabel 4.34 Matriks Konfusi Data Pengujian Model BiLSTM Terbaik (<i>Data Imbalance</i>)	57
Tabel 4.35 Evaluasi Performa Data Pelatihan Model BiLSTM Terbaik (<i>Data Imbalance</i>)	58
Tabel 4.36 Evaluasi Performa Data Pengujian Model BiLSTM Terbaik (<i>Data Imbalance</i>)	58

Tabel 4.37 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi GRU (<i>Data Imbalance</i>)	59
Tabel 4.38 Matriks Konfusi Data Pelatihan Model GRU Terbaik (<i>Data Imbalance</i>)	60
Tabel 4.39 Matriks Konfusi Data Pengujian Model GRU Terbaik (<i>Data Imbalance</i>)	60
Tabel 4.40 Evaluasi Performa Data Pelatihan Model GRU Terbaik (<i>Data Imbalance</i>)	61
Tabel 4.41 Evaluasi Performa Data Pengujian Model GRU Terbaik (<i>Data Imbalance</i>)	61
Tabel 4.42 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi CNN-LSTM (<i>Data Imbalance</i>)	62
Tabel 4.43 Matriks Konfusi Data Pelatihan Model CNN-LSTM Terbaik (<i>Data Imbalance</i>)	63
Tabel 4.44 Matriks Konfusi Data Pengujian Model CNN-LSTM Terbaik (<i>Data Imbalance</i>)	63
Tabel 4.45 Evaluasi Performa Data Pelatihan Model CNN-LSTM Terbaik (<i>Data Imbalance</i>)	64
Tabel 4.46 Evaluasi Performa Data Pengujian Model CNN-LSTM Terbaik (<i>Data Imbalance</i>)	64
Tabel 4.47 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi CNN-BiLSTM (<i>Data Imbalance</i>)	65
Tabel 4.48 Matriks Konfusi Data Pelatihan Model CNN-BiLSTM Terbaik (<i>Data Imbalance</i>)	66
Tabel 4.49 Matriks Konfusi Data Pengujian Model CNN-BiLSTM Terbaik (<i>Data Imbalance</i>)	66
Tabel 4.50 Evaluasi Performa Data Pelatihan Model CNN-BiLSTM Terbaik (<i>Data Imbalance</i>)	67
Tabel 4.51 Evaluasi Performa Data Pengujian Model CNN-BiLSTM Terbaik (<i>Data Imbalance</i>)	67
Tabel 4.52 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi CNN-GRU (<i>Data Imbalance</i>)	68

Tabel 4.53 Matriks Konfusi Data Pelatihan Model CNN-GRU Terbaik (<i>Data Imbalance</i>)	69
Tabel 4.54 Matriks Konfusi Data Pengujian Model CNN-GRU Terbaik (<i>Data Imbalance</i>)	69
Tabel 4.55 Evaluasi Performa Data Pelatihan Model CNN-GRU Terbaik (<i>Data Imbalance</i>)	70
Tabel 4.56 Evaluasi Performa Data Pengujian Model CNN-GRU Terbaik (<i>Data Imbalance</i>)	70
Tabel 4.57 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi LSTM (<i>Data Balance</i>)	71
Tabel 4.58 Matriks Konfusi Data Pelatihan Model LSTM Terbaik (<i>Data Balance</i>)	72
Tabel 4.59 Matriks Konfusi Data Pengujian Model LSTM Terbaik (<i>Data Balance</i>)	72
Tabel 4.60 Evaluasi Performa Data Pelatihan Model LSTM Terbaik (<i>Data Balance</i>)	73
Tabel 4.61 Evaluasi Performa Data Pengujian Model LSTM Terbaik (<i>Data Balance</i>)	73
Tabel 4.62 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi BiLSTM (<i>Data Balance</i>)	74
Tabel 4.63 Matriks Konfusi Data Pelatihan Model BiLSTM Terbaik (<i>Data Balance</i>)	75
Tabel 4.64 Matriks Konfusi Data Pengujian Model BiLSTM Terbaik (<i>Data Balance</i>)	75
Tabel 4.65 Evaluasi Performa Data Pelatihan Model BiLSTM Terbaik (<i>Data Balance</i>)	76
Tabel 4.66 Evaluasi Performa Data Pengujian Model BiLSTM Terbaik (<i>Data Balance</i>)	76
Tabel 4.67 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi GRU (<i>Data Balance</i>)	77
Tabel 4.68 Matriks Konfusi Data Pelatihan Model GRU Terbaik (<i>Data Balance</i>)	78

Tabel 4.69 Matriks Konfusi Data Pengujian Model GRU Terbaik (<i>Data Balance</i>).....	78
Tabel 4.70 Evaluasi Performa Data Pelatihan Model GRU Terbaik (<i>Data Balance</i>).....	79
Tabel 4.71 Evaluasi Performa Data Pengujian Model GRU Terbaik (<i>Data Balance</i>).....	79
Tabel 4.72 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi CNN-LSTM (<i>Data Balance</i>).....	80
Tabel 4.73 Matriks Konfusi Data Pelatihan Model CNN-LSTM Terbaik (<i>Data Balance</i>).....	81
Tabel 4.74 Matriks Konfusi Data Pengujian Model CNN-LSTM Terbaik (<i>Data Balance</i>).....	81
Tabel 4.75 Evaluasi Performa Data Pelatihan Model CNN-LSTM Terbaik (<i>Data Balance</i>).....	82
Tabel 4.76 Evaluasi Performa Data Pengujian Model CNN-LSTM Terbaik (<i>Data Balance</i>).....	82
Tabel 4.77 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi CNN-BiLSTM. (<i>Data Balance</i>).....	83
Tabel 4.78 Matriks Konfusi Data Pelatihan Model CNN-BiLSTM Terbaik (<i>Data Balance</i>).....	84
Tabel 4.79 Matriks Konfusi Data Pengujian Model CNN-BiLSTM Terbaik (<i>Data Balance</i>).....	84
Tabel 4.80 Evaluasi Performa Data Pelatihan Model CNN-BiLSTM Terbaik (<i>Data Balance</i>).....	85
Tabel 4.81 Evaluasi Performa Data Pengujian Model CNN-BiLSTM Terbaik (<i>Data Balance</i>).....	85
Tabel 4.82 Perbandingan Hasil Evaluasi Pengujian Model pada Algoritma Klasifikasi CNN-GRU (<i>Data Balance</i>).....	86
Tabel 4.83 Matriks Konfusi Data Pelatihan Model CNN-GRU Terbaik (<i>Data Balance</i>).....	87
Tabel 4.84 Matriks Konfusi Data Pengujian Model CNN-GRU Terbaik (<i>Data Balance</i>).....	87

Tabel 4.85 Evaluasi Performa Data Pelatihan Model CNN-GRU Terbaik (<i>Data Balance</i>).....	88
Tabel 4.86 Evaluasi Performa Data Pengujian Model CNN-GRU Terbaik (<i>Data Balance</i>).....	88
Tabel 4.87 Perbandingan Hasil Pengujian untuk Setiap Model dan Algoritma Klasifikasi pada <i>Data Imbalance</i>	90
Tabel 4.88 Perbandingan Hasil Pengujian untuk Setiap Model dan Algoritma Klasifikasi pada <i>Data Balance</i>	94
Tabel 4.89 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi RNN (<i>Data Imbalance</i>).....	99
Tabel 4.90 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi CNN+RNN (<i>Data Imbalance</i>).....	99
Tabel 4.91 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi RNN (<i>Data Balance</i>).....	100
Tabel 4.91 Perbandingan Hasil Evaluasi Pengujian Model Terbaik Algoritma Klasifikasi RNN (<i>Data Balance</i>).....	100

DAFTAR LAMPIRAN

LAMPIRAN 1. Form Revisi Ujian Sidang Tugas Akhir II

LAMPIRAN 2. Hasil Pengecekan Plagiat *Software Authenticate/Turnitin*

BAB I

PENDAHULUAN

1.1. Latar Belakang

Atrial Fibrillation (AF) adalah sebuah kelainan pada sistem sinyal kelistrikan yang mengatur irama detak jantung manusia [7]. Penyakit ini merupakan jenis *arrhythmia* yang biasanya menjadi faktor potensial dari penyakit stroke [8]. Selain itu, AF dapat juga menjadi salah satu penyebab penyakit gagal jantung, hal ini dikarenakan gangguan sinyal kelistrikan pada jantung akan membuat detak jantung menjadi tidak teratur dan lama kelamaan menjadi sangat cepat [7].

Penyakit AF merupakan salah satu jenis *cardiac arrhythmia* yang paling umum. Jika terdeteksi AF, maka perubahan morfologi Elektrokardiogram (EKG) dapat dideteksi dan dapat diidentifikasi secara visual oleh seorang ahli. Deteksi secara manual pada record sinyal EKG yang dilakukan oleh seorang ahli seringkali tidak tepat dan menjadi kurang praktis [7]. Selain itu deteksi tersebut memerlukan ahli kesehatan yang terlatih secara khusus untuk membaca dan mengidentifikasi sinyal ECG tidak teratur secara manual. Proses tersebut juga seringkali membutuhkan proses dan waktu yang lama [9]. Berdasarkan hal tersebut, deteksi otomatis penyakit AF menggunakan sinyal EKG menjadi bidang penelitian yang sangat penting pada saat ini.

Beberapa metode sudah banyak sekali digunakan untuk mendeteksi penyakit AF menggunakan sinyal EKG. Salah satu metode yang digunakan adalah metode *Deep Learning*. Salah satu contoh metode *Deep Learning* yang digunakan adalah *Convolutional Neural Network* yang dilakukan oleh [10] dan [11]. Metode *Deep Learning* digunakan karena dapat memaksimalkan penggunaan semua informasi yang berasal input, sehingga keputusan yang diambil menjadi lebih kuat dan baik [12].

Model *Deep Learning* yang akhir-akhir ini memiliki popularitas yang tinggi adalah *Recurrent Neural Network* (RNN). Arsitektur RNN bekerja dengan

menyimpan dan menggunakan informasi sebelumnya sehingga keputusan yang diambil menjadi lebih kuat. Hal inilah yang membuat RNN sangat cocok untuk data sekuensial seperti sinyal ECG. Dalam interval input yang panjang, RNN dapat menangani dependensi input panjang tersebut dengan cara penurunan gradien. Hal ini tentu saja menjadi tidak efisien karena rentang temporal dari dependensi input menjadi meningkat dan akan mempengaruhi hasil dari pembelajaran model. Karena hal tersebut, RNN menjadi sulit untuk dilatih dengan sukses pada input yang memiliki interval panjang [12].

Oleh karena itu, arsitektur *Long Short-Term Memory* (LSTM) dikembangkan untuk membantu dalam mengatasi masalah yang terjadi tersebut dan arsitektur ini juga meningkatkan hasil dari model RNN standar. Hal ini dilakukan dengan memasukkan mekanisme gating sehingga dapat meningkatkan penanganan informasi dari input dengan yang interval panjang. Dengan menggunakan model LSTM, keputusan yang diambil menjadi lebih baik dibandingkan dengan menggunakan model RNN standar [12]. Selain LSTM, ada pula arsitektur lainnya seperti *Bidirectional Long Short-Term Memory* (BiLSTM) dan juga *Gated Recurrent Unit* (GRU).

Adapun optimisasi parameter yang digunakan oleh model LSTM dilakukan dengan menggunakan algoritma Grid Search. Algoritma ini dipilih karena dapat membantu model menemukan parameter terbaik sehingga performa yang dihasilkan menjadi lebih baik dan tinggi [13].

1.2 Tujuan dan Manfaat

1.2.1 Tujuan

Tujuan yang ingin dicapai dalam penulisan Tugas Akhir ini antara lain:

1. Menemukan fungsi wavelet terbaik yang dapat menghilangkan derau sinyal dengan baik.
2. Menemukan model terbaik *Recurrent Neural Network* yang sesuai untuk memperoleh dan meningkatkan hasil deteksi penyakit *Atrial Fibrillation*.

3. Menemukan parameter yang sesuai untuk model *Recurrent Neural Network* yang telah dibuat untuk meningkatkan kinerja model dan memperoleh hasil yang lebih baik

1.2.2 Manfaat

Manfaat yang akan didapatkan dari penulisan Tugas Akhir ini antara lain adalah:

1. Dapat digunakan untuk membantu para ahli jantung dalam mendiagnosa penyakit *Atrial Fibrillation* dengan lebih mudah.
2. Dapat digunakan sebagai rancangan sistem dalam perancangan ECG *mobile device*.

1.3. Perumusan dan Batasan Masalah

1.3.1. Perumusan Masalah

Rumusan masalah pada Tugas Akhir ini adalah bagaimana membangun model terbaik *Recurrent Neural Network* yang tepat sehingga dapat mendeteksi penyakit *Atrial Fibrillation* secara akurat dengan melakukan optimisasi parameter pada yang telah dirancang.

1.3.2. Batasan Masalah

Berikut batasan masalah yang ada pada Tugas Akhir ini.

1. Data penelitian yang digunakan adalah data *PhysioNet/CinC Challenge 2017*.
2. Penelitian ini hanya berfokus pada proses mencari dan membangun model terbaik *Recurrent Neural Network* yang sesuai agar dapat mendeteksi penyakit *Atrial Fibrillation* secara akurat.
3. Proses penelitian hanya mencakup simulasi program dengan penggunaan *Python* sebagai bahasa pemrograman.

1.4. Metodologi Penelitian

Metodologi penelitian yang digunakan untuk penyusunan Tugas Akhir ini adalah:

1.4.1. Tahapan Pertama (Persiapan Data)

Tahap pertama yang dilakukan adalah persiapan data dengan mengambil dan mengekstrak data sinyal yang akan digunakan. Setelah itu, dilakukan juga analisis terhadap data yang diambil.

1.4.2. Tahap Kedua (Pra Pengolahan Data)

Melakukan pra pengolahan terhadap data sinyal yang telah diambil dengan tujuan agar data sinyal menjadi lebih bagus sebelum masuk ke dalam model. Adapun tahapan pra pengolahan yang dilakukan adalah menghilangkan derau dengan menggunakan metode *Discrete Wavelet Transform* dan juga normalisasi. Kemudian data sinyal akan diatur jumlah *window size* sehingga bisa digunakan sebagai input model yang akan dibangun.

1.4.3. Tahap Ketiga (Membagi Data Latih dan Data Uji)

Data yang telah melalui proses pra-pengolahan, selanjutnya akan dibagi menjadi dua. Data tersebut akan digunakan sebagai data untuk proses pelatihan model dan untuk data dalam proses pengujian model.

1.4.4. Tahap Keempat (Perancangan Arsitektur Model)

Pada tahap ini dilakukan perancangan arsitektur model untuk proses deteksi penyakit *Atrial Fibrillation*. Adapun parameter yang akan digunakan nantinya akan dituning agar memperoleh model dengan kinerja terbaik.

1.4.5. Tahap Kelima (Tuning Parameter, Pengujian dan Validasi Hasil)

Tuning parameter yang akan digunakan dilakukan dengan menggunakan algoritma *Grid Search*. Proses tuning ini juga sekaligus sebagai proses pengujian model yang telah dibuat dengan menggunakan berbagai jenis parameter yang telah ditentukan. Hasil pengujian nantinya akan divalidasi agar sesuai dengan kinerja yang diharapkan.

1.4.6. Tahap Keenam (Analisa dan Kesimpulan)

Pada tahapan terakhir ini, akan dilakukan proses analisa mengenai hasil yang telah didapatkan. Hasil dari proses analisa ini nantinya dapat berguna untuk menarik kesimpulan dan juga sebagai referensi untuk penelitian terkait ke depannya.

1.5. Sistematika Penulisan

Tujuan dibuatnya sistematika penulisan adalah untuk membantu mempermudah penyusunan Tugas Akhir. Selain itu, sistematika penulisan akan membuat isi dari setiap bab yang ada pada Tugas Akhir menjadi lebih jelas. Sistematika penulisan pada Tugas Akhir ini adalah sebagai berikut:

BAB I – PENDAHULUAN

Bagian ini merupakan awal dari proses penelitian yang akan dilakukan, bab ini akan berisi Latar Belakang Masalah. Kemudian Tujuan dan Manfaat, Perumusan dan Batasan Masalah, Metode Penelitian, dan Sistematika Penulisan juga akan masuk ke dalam bagian pendahuluan ini.

BAB II – TINJAUAN PUSTAKA

Bagian ini akan membahas mengenai penjelasan Dasar Teori, Konsep dan Prinsip Dasar yang berhubungan dengan penelitian yang akan dilakukan. Teori serta prinsip dasar tersebut nantinya akan dibutuhkan dalam proses pemecahan masalah yang dialami selama penelitian.

BAB III – METODOLOGI

Pada bagian ini, metodologi yang digunakan pada proses penelitian akan dibahas secara rinci. Metodologi tersebut menyangkut tentang teknik, metode, dan alur proses yang dilakukan dalam penelitian.

BAB IV – HASIL DAN ANALISA SEMENTARA

Hasil dari pengujian dan analisis yang diperoleh selama penelitian akan dibahas pada bab ini. Selain itu, pembahasan mengenai hasil penelitian yang telah dicapai pun akan dibahas, seperti kelebihan dan kekurangan dari penelitian.

BAB V – KESIMPULAN DAN SARAN

Bab terakhir ini akan berisi kesimpulan yang didapatkan dari hasil penelitian. Selain itu, bab ini juga berisi saran untuk penelitian selanjutnya yang berhubungan dengan penelitian yang dikerjakan ini.

DAFTAR PUSTAKA

- [1] H. Abrishami, C. Han, X. Zhou, M. Campbell, and R. Czosek, “Supervised ecg interval segmentation using lstm neural network,” in *Proceedings of the International Conference on Bioinformatics & Computational Biology (BIOCOMP)*, 2018, pp. 71–77.
- [2] M. Aqil, A. Jbari, and A. Bourouhou, “ECG signal denoising by discrete wavelet transform,” *Int. J. Online Biomed. Eng.*, vol. 13, no. 09, pp. 51–68, 2017.
- [3] A. Graps, “An introduction to wavelets,” *IEEE Comput. Sci. Eng.*, vol. 2, no. 2, pp. 50–61, 1995.
- [4] Ö. Yildirim, “A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification,” *Comput. Biol. Med.*, vol. 96, pp. 189–202, 2018.
- [5] A. Darmawahyuni, S. Nurmaini, W. Caesarendra, V. Bhayyu, M. N. Rachmatullah, and others, “Deep Learning with a Recurrent Network Structure in the Sequence Modeling of Imbalanced Data for ECG-Rhythm Classifier,” *Algorithms*, vol. 12, no. 6, p. 118, 2019.
- [6] H. M. Lynn, S. B. Pan, and P. Kim, “A deep bidirectional GRU network model for biometric electrocardiogram classification based on recurrent neural networks,” *IEEE Access*, vol. 7, pp. 145395–145405, 2019.
- [7] R. Banerjee, A. Ghose, and S. Khandelwal, “A Novel Recurrent Neural Network Architecture for Classification of Atrial Fibrillation Using Single-lead ECG,” in *2019 27th European Signal Processing Conference (EUSIPCO)*, 2019, pp. 1–5.
- [8] A. S. Go *et al.*, “Prevalence of diagnosed atrial fibrillation in adults: national implications for rhythm management and stroke prevention: the AnTicoagulation and Risk Factors in Atrial Fibrillation (ATRIA) Study,”

- Jama*, vol. 285, no. 18, pp. 2370–2375, 2001.
- [9] Z. Xiong, M. P. Nash, E. Cheng, V. V. Fedorov, M. K. Stiles, and J. Zhao, “ECG signal classification for the detection of cardiac arrhythmias using a convolutional recurrent neural network,” *Physiol. Meas.*, vol. 39, no. 9, pp. 1–14, 2018, doi: 10.1088/1361-6579/aad9ed.
 - [10] Y. Xia, N. Wulan, K. Wang, and H. Zhang, “Detecting atrial fibrillation by deep convolutional neural networks,” *Comput. Biol. Med.*, vol. 93, pp. 84–92, 2018.
 - [11] S. Nurmaini *et al.*, “Robust detection of atrial fibrillation from short-term electrocardiogram using convolutional neural networks,” *Futur. Gener. Comput. Syst.*, vol. 113, pp. 304–317, 2020.
 - [12] O. Faust, A. Shenfield, M. Kareem, T. R. San, H. Fujita, and U. R. Acharya, “Automated detection of atrial fibrillation using long short-term memory network with RR interval signals,” *Comput. Biol. Med.*, vol. 102, pp. 327–335, 2018.
 - [13] I. Syarif, A. Prugel-Bennett, and G. Wills, “SVM parameter optimization using grid search and genetic algorithm to improve classification performance,” *Telkommika (Telecommunication Comput. Electron. Control.)*, vol. 14, no. 4, pp. 1502–1509, 2016, doi: 10.12928/TELKOMNIKA.v14i4.3956.
 - [14] G. Petmezas *et al.*, “Automated Atrial Fibrillation Detection using a Hybrid CNN-LSTM Network on Imbalanced ECG Datasets,” *Biomed. Signal Process. Control*, vol. 63, p. 102194, 2021.
 - [15] N. Fayyazifar, “An Accurate CNN Architecture For Atrial Fibrillation Detection Using Neural Architecture Search,” in *2020 28th European Signal Processing Conference (EUSIPCO)*, 2020, pp. 1135–1139.
 - [16] R. Hassan and S. Shaker, “ECG Signal De-Noising and Feature Extraction using Discrete Wavelet Transform,” *Int. J. Eng. Trends Technol.*, vol. 63,

- no. 1, pp. 32–39, 2018.
- [17] G. Chen, M. Chen, J. Zhang, L. Zhang, and C. Pang, “A Crucial Wave Detection and Delineation Method for Twelve-Lead ECG Signals,” *IEEE Access*, vol. 8, pp. 10707–10717, 2020.
 - [18] S. M. Mathews, C. Kambhamettu, and K. E. Barner, “A novel application of deep learning for single-lead ECG classification,” *Comput. Biol. Med.*, vol. 99, pp. 53–62, 2018.
 - [19] S. Savalia and V. Emamian, “Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks,” *Bioengineering*, vol. 5, no. 2, p. 35, 2018.
 - [20] Y. Hagiwara *et al.*, “Computer-aided diagnosis of atrial fibrillation based on ECG signals: A review,” *Inf. Sci. (Ny.)*, vol. 467, pp. 99–114, 2018.
 - [21] S. Nurmaini, A. Gani, and others, “Cardiac Arrhythmias Classification Using Deep Neural Networks and Principle Component Analysis Algorithm.,” *Int. J. Adv. Soft Comput. Its Appl.*, vol. 10, no. 2, 2018.
 - [22] T. B. Garcia, *12-lead ECG: The art of interpretation*. Jones & Bartlett Publishers, 2013.
 - [23] R. Chauhan, R. Dahiya, and P. Bansal, “Optimal choice of thresholding rule for denoising ECG using DWT,” in *2017 4th International Conference on Signal Processing, Computing and Control (ISPCC)*, 2017, pp. 288–292.
 - [24] H.-Y. Lin, S.-Y. Liang, Y.-L. Ho, Y.-H. Lin, and H.-P. Ma, “Discrete-wavelet-transform-based noise removal and feature extraction for ECG signals,” *Irbm*, vol. 35, no. 6, pp. 351–361, 2014.
 - [25] P. Karthikeyan, M. Murugappan, and S. Yaacob, “ECG Signal Denoising Using Wavelet Thresholding Techniques in Human Stress Assessment,” *Int. J. Electr. Eng. Informatics*, vol. 4, no. 2, pp. 306–319, 2012.

- [26] R. S. Andersen, A. Peimankar, and S. Puthusserypady, “A deep learning approach for real-time detection of atrial fibrillation,” *Expert Syst. Appl.*, vol. 115, pp. 465–473, 2019.
- [27] S. Nurmaini, A. Darmawahyuni, A. N. Sakti Mukti, M. N. Rachmatullah, F. Firdaus, and B. Tutuko, “Deep Learning-Based Stacked Denoising and Autoencoder for ECG Heartbeat Classification,” *Electronics*, vol. 9, no. 1, p. 135, 2020.
- [28] E. Choi, A. Schuetz, W. F. Stewart, and J. Sun, “Using recurrent neural network models for early detection of heart failure onset,” *J. Am. Med. Informatics Assoc.*, vol. 24, no. 2, pp. 361–370, 2017.
- [29] J. A. Bullinaria, “Recurrent neural networks,” *Neural Comput. Lect.*, vol. 12, 2013.
- [30] S. Singh, S. K. Pandey, U. Pawar, and R. R. Janghel, “Classification of ECG arrhythmia using recurrent neural networks,” *Procedia Comput. Sci.*, vol. 132, pp. 1290–1297, 2018.
- [31] A. Ullah, J. Ahmad, K. Muhammad, M. Sajjad, and S. W. Baik, “Action recognition in video sequences using deep bi-directional LSTM with CNN features,” *IEEE Access*, vol. 6, pp. 1155–1166, 2017.
- [32] G. S. Chadha, A. Panambilly, A. Schwung, and S. X. Ding, “Bidirectional deep recurrent neural networks for process fault classification,” *ISA Trans.*, 2020.
- [33] K. Kim, “Arrhythmia classification in multi-channel ECG signals using deep neural networks,” 2018.
- [34] A. Darmawahyuni, S. Nurmaini, and others, “Deep Learning with Long Short-Term Memory for Enhancement Myocardial Infarction Classification,” in *2019 6th International Conference on Instrumentation, Control, and Automation (ICA)*, 2019, pp. 19–23.

- [35] M. Cheng, W. J. Sori, F. Jiang, A. Khan, and S. Liu, “Recurrent neural network based classification of ECG signal features for obstruction of sleep apnea detection,” in *2017 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC)*, 2017, vol. 2, pp. 199–202.
- [36] Z. Cui, R. Ke, Z. Pu, and Y. Wang, “Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Forecasting Network-wide Traffic State with Missing Values,” *arXiv Prepr. arXiv2005.11627*, 2020.
- [37] B. Qolomany, M. Maabreh, A. Al-Fuqaha, A. Gupta, and D. Benhaddou, “Parameters optimization of deep learning models using Particle swarm optimization,” in *2017 13th International Wireless Communications and Mobile Computing Conference (IWCMC)*, 2017, pp. 1285–1290.
- [38] I. Syarif, A. Prugel-Bennett, and G. Wills, “SVM parameter optimization using grid search and genetic algorithm to improve classification performance,” *Telkommika*, vol. 14, no. 4, p. 1502, 2016.
- [39] G. D. Clifford *et al.*, “AF Classification from a short single lead ECG recording: the PhysioNet/Computing in Cardiology Challenge 2017,” in *2017 Computing in Cardiology (CinC)*, 2017, pp. 1–4.