

**KLASIFIKASI BEAT EKG SECARA DEEP LEARNING
MENGGUNAKAN AUTOENCODER DAN DEEP
NEURAL NETWORK**

TUGAS AKHIR

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



**VICKO BHAYYU
09011181520036**

**JURUSAN SISTEM KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2019**

LEMBAR PENGESAHAN

**KLASIFIKASI BEAT EKG SECARA DEEP LEARNING
MENGGUNAKAN AUTOENCODER DAN DEEP NEURAL NETWORK**

TUGAS AKHIR

**Program Studi Sistem Komputer
Jenjang S1**

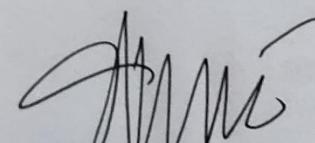
Oleh

**Vicko Bhayyu
09011181520036**

Indralaya, Juli 2019

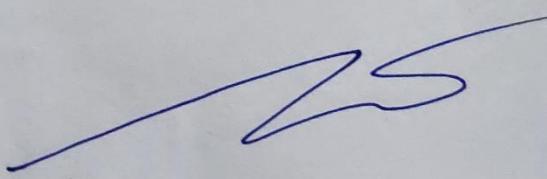
Mengetahui,

Pembimbing Tugas Akhir



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

Ketua Jurusan Sistem Komputer



**Rossi Passarella, S.T., M.Eng.
NIP. 19780611 201012 1 004**

HALAMAN PERSETUJUAN

Telah diuji dan lulus pada :

Hari : Rabu

Tanggal : 24 Juli 2019

Tim Penguji :

1. Ketua : Sarmayanta Sembiring, S.Si., M.T.

2. Anggota I : Dr. Erwin, S.Si., M.Si.

3. Anggota II : Firdaus, S.T., M.Kom.

**Mengetahui,
Ketua Jurusan Sistem Komputer**

**Rossi Passarella, S.T., M.Eng.
NIP. 19780611 201012 1 004**

HALAMAN PERNYATAAN

Yang bertanda tangan dibawah ini :

Nama : Vicko Bhayyu

NIM : 09011181520036

Judul : Klasifikasi Beat EKG secara Deep Learning

menggunakan Autoencoder dan Deep Neural Network

Hasil Pengecekan *Software iThenticate/Turnitin* : 4%

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

Demikian, pernyataan ini saya buat dalam keadaan sadar dan tidak dipaksakan.

Palembang, 15 Juli 2019



Vicko Bhayyu

NIM. 09011181520036

KATA PENGANTAR

Shalom, puji dan rasa syukur penulis panjatkan kepada Tuhan Yang Maha Esa, atas segala karunia, berkat, dan rahmat-Nya sehingga penulis dapat menyelesaikan penyusunan Proposal Tugas Akhir ini dengan judul “Klasifikasi Beat EKG Secara Deep Learning Menggunakan Autoencoder dan Deep Neural Network”.

Dalam laporan ini penulis menjelaskan mengenai Klasifikasi Beat EKG Menggunakan Autoencoder dan Deep Neural Network dengan disertai data-data yang diperoleh penulis saat melakukan pengujian. Penulis berharap tulisan ini dapat bermanfaat bagi orang banyak, dan menjadi tambahan bahan bacaan bagi yang tertarik para teman-teman peneliti lain yang juga berada di bidang medis khususnya penyakit jantung dan elektrokardiogram.

Pada penyusunan laporan ini, penulis banyak mendapatkan ide dan saran serta bantuan dari berbagai pihak baik secara langsung maupun tidak langsung. Oleh karena itu, pada kesempatan ini penulis mengucapkan rasa syukur kepada Tuhan Yang Maha Esa dan terimakasih kepada yang terhormat :

1. Kedua orang tua beserta keluarga yang selalu mendoakan serta memberikan motivasi dan semangat.
2. Bapak Jaidan Jauhari, S.Pd. M.T selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
3. Bapak Rossi Passarella, S.T.,M.Eng selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya
4. Ibu Prof. Dr. Ir. Siti Nurmaini, M.T. selaku Pembimbing Tugas Akhir Penulis yang selalu memberikan nasihat, arahan dan dukungan moril selama pembuatan tugas akhir.
5. Bapak Dr. Erwin, M.Si., selaku Dosen Pembimbing Akademik di Jurusan Sistem Komputer dan Dosen Penguji Tugas Akhir yang selalu memberikan nasihat selama proses perkuliahan dan tugas akhir.
6. Bapak Firdaus, M.Kom., selaku Dosen Penguji Tugas Akhir yang selalu memberikan nasihat selama proses perkuliahan, pembelajaran, dan tugas akhir.

7. Seluruh bapak/ibu dosen yang ada di Jurusan Sistem Komputer.
8. Kak Reza dan Mbak Winda selaku Admin di Jurusan Sistem Komputer yang sangat membantu mengurus semua proses administrasi.
9. Kak Naufal dan Mbak Nisa, yang turut membantu memberikan arahan serta nasihat dalam pembuatan tugas akhir.
10. Teman – teman seperjuangan (Andre, Ferlita, Rahmi, Ujuk, Varindo, dll) di Intelligent System Research Group.
11. Teman – teman dari Jurusan Sistem Komputer yang tidak bisa disebutkan satu-persatu.
12. Dan semua pihak yang telah membantu secara langsung maupun secara tidak langsung.

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.

Palembang, Maret 2019

Penulis

KLASIFIKASI BEAT EKG SECARA DEEP LEARNING MENGGUNAKAN AUTOENCODER DAN DEEP NEURAL NETWORK

VICKO BHAYYU (09011181520036)

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

ABSTRAK

Elektrokardiografi (EKG) merupakan pengujian medis untuk pemeriksaan kondisi jantung dalam sebuah representasi sinyal listrik yang memberikan informasi klinis mengenai jantung pasien. Dengan EKG, kardiologis mampu mendiagnosa kondisi jantung pasien baik secara detak jantung ataupun ritme jantung. Klasifikasi beat EKG dengan jumlah data yang banyak memiliki tantangan tersendiri sehingga metode Deep Learning yang memiliki tingkat abstraksi yang tinggi dalam mempelajari fitur sangat diunggulkan. Dengan metode Autoencoder sebagai fitur ekstraksi untuk mempelajari fitur serta mengurangi dimensi fitur dan Deep Neural Network sebagai klasifier beat EKG. Dimensi fitur beat EKG dari data mentah sebesar 252 dilakukan fitur ekstraksi oleh Autoencoder yang kemudian direduksi menjadi 32. Hasil fitur ekstraksi ini kemudian diklasifikasikan oleh Deep Neural Network dengan jumlah kelas sebanyak 10. Dilakukan sebanyak 15 model percobaan dengan model terbaik akan diujikan kembali ke dataset lain. Dari 15 model percobaan, didapat model terbaik yakni Deep AE – DNN 3 HL, dengan hasil akurasi, sensitivitas, spesifisitas, presisi, dan F1- Score masing-masing 99.59%, 91.02%, 99.8%, 93.06%, 91,79%. Kemudian model ini diujikan kembali ke dataset lain yakni SVDB dan IncartDB dengan hasil akurasi 99.5%, sensitivitas 89.6%, spesifisitas 98,39%, presisi 97.62%, dan F1-Score 93,07% untuk IncartDB dan akurasi 97,86%, sensitivitas 87.28%, spesifisitas 94%, presisi 91.91%, F1-Score 89,46%.

Kata Kunci : Elektrokardiografi, Klasifikasi, Autoencoder, Deep Neural Network.

KLASIFIKASI BEAT EKG SECARA DEEP LEARNING MENGGUNAKAN AUTOENCODER DAN DEEP NEURAL NETWORK

VICKO BHAYYU (09011181520036)

Dept.of Computer Engineering, Faculty of Computer Science, Sriwijaya

University

Email: vickobhayyu@gmail.com

ABSTRACT

Electrocardiograph (ECG) is medical testing for examining heart condition in an electrical signal to provide clinical information about a patient's heart. With ECG, Cardiologists can diagnose the patient's heart condition either by heartbeats or rhythm. ECG beat classification with a large amount of data has its challenges so that the Deep Learning method that has a high level of abstraction in learning features is highly favored. With the Autoencoder method as feature extraction to learn features and reduce feature dimensions and Deep Neural Network as an ECG beat classifier. The dimension of ECG beat features from raw data is 252 then perform extraction feature by Autoencoder which is then reduced to 32. The results of this extraction feature are then classified by Deep Neural Network with 10 classes. Conducted as many as 15 experimental models with the best model will be tested to another dataset. From the 15 experimental models, the best models are obtained, namely Deep AE - DNN 3 HL, with the results of accuracy, sensitivity, specificity, precision, and F1-Score respectively 99.59%, 91.02%, 99.8%, 93.06%, 91.79%. Then this model was tested back to other datasets SVDB and IncartDB with 99.5% accuracy results, 89.6% sensitivity, 98.39% specificity, 97.62% precision, and F1-Score 93.07% for IncartDB and 97.86% accuracy, sensitivity 87.28%, specificity 94%, precision 91.91%, F1-Score 89.46%.

Key Words : *Electrocardiograph, Classification, Autoencoder, Deep Neural Network.*

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
HALAMAN PENGESAHAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI	ix
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xviii
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Tujuan	2
1.3 Perumusan Masalah	3
1.4 Sistematika Penulisan	3
BAB II TINJAUAN PUSTAKA	
2.1 Pendahuluan	5
2.2 Elektrokardiogram	5
2.3 Gelombang EKG.....	5
2.4 MIT-BIH <i>Arrhythmia Database</i>	8
2.5 <i>Artificial Neural Network (ANN)</i>	9
2.6 Fungsi Aktivasi	10
2.6.1 Fungsi <i>Sigmoid</i>	10
2.6.2 Fungsi <i>Tanh</i>	11
2.6.3 Fungsi <i>Rectified Linear Unit</i>	12
2.6.4 Fungsi <i>Softmax</i>	13
2.7 Fungsi <i>Loss</i>	14
2.7.1 Loss Mean Squared Error	14

2.7.2 Loss Crossentropy	14
2.8 Metode Optimasi.....	15
2.9 <i>Deep Neural Network</i> (DNN)	16
2.10 <i>Autoencoder</i> (AE)	20
2.11 Matriks Konfusi	22
2.11.1 Akurasi	23
2.11.2 Spesifisitas	23
2.11.3 Sensitifitas	23
2.11.4 Presisi	24
2.11.5 F1-Score	24
2.11.6 Kurva ROC	24
2.11.7 Kurva Presisi-Recall	25

BAB III METODOLOGI PENELITIAN

3.1 Pendahuluan	26
3.2 Kerangka Kerja	26
3.3 Akuisisi Data	28
3.4 Pra-Pemrosesan	33
3.4.1 Normalisasi	33
3.4.2 <i>Dimensionality Reduction</i> dengan Autoencoder	34
3.5 Pembagian Data Latih dan Data Uji untuk Klasifikasi	36
3.6 Klasifikasi dengan <i>Deep Neural Network</i>	36
3.7 Validasi	38

BAB IV HASIL DAN PEMBAHASAN

4.1 Pendahuluan	39
4.2 Pengujian Segmentasi Beat EKG	39
4.3 Pengujian Normalisasi	40
4.4 Pengujian Reduksi Dimensi dengan <i>Autoencoder</i>	41
4.4.1 <i>Autoencoder 1 Hidden Layer</i>	41
4.4.2 <i>Deep Autoencoder</i>	47
4.5 Pengujian Klasifikasi dengan <i>Deep Neural Network</i>	53
4.5.1 MLP 1 HL	53

4.5.1.1 AE 1 HL dan MLP 1 HL	53
4.5.1.2 Deep AE dan MLP 1 HL	60
4.5.1.3 Tanpa AE dan MLP 1 HL	66
4.5.2 MLP 2 HL	74
4.5.2.1 AE 1 HL dan MLP 2 HL	74
4.5.2.2 Deep AE dan MLP 2 HL	81
4.5.2.3 Tanpa AE dan MLP 2 HL	88
4.5.3 DNN 3 HL	96
4.5.3.1 AE 1 HL dan DNN 3 HL	96
4.5.3.2 Deep AE dan DNN 3 HL	103
4.5.3.3 Tanpa AE dan DNN 3 HL	109
4.5.4 DNN 4 HL	116
4.5.4.1 AE 1 HL dan DNN 4 HL	116
4.5.4.2 Deep AE dan DNN 4 HL	123
4.5.4.3 Tanpa AE dan DNN 4 HL	128
4.5.5 DNN 5 HL	135
4.5.5.1 AE 1 HL dan DNN 5 HL	135
4.5.5.2 Deep AE dan DNN 5 HL	142
4.5.5.3 Tanpa AE dan DNN 5 HL	149
4.6 Perbandingan 5 parameter evaluasi terhadap 3 model data	156
4.7 Generalisasi Fitur terhadap Dataset lain.	
4.7.1 Dataset IncartDB	159
4.7.2 Dataset SVDB	163
4.7.3 Perbandingan Hasil Generalisasi Fitur pada Dataset lain	168
4.8 Pengujian Tambahan : Pengujian Klasifikasi dengan	
Penghilangan Derau pada dataset lain	169
4.8.1 Pengujian Klasifikasi dengan Penghilangan Derau pada	
Dataset IncartDB	170
4.8.2 Pengujian Klasifikasi dengan Penghilangan Derau pada	
Dataset SVDB	174
4.8.3 Perbandingan Hasil Generalisasi Fitur tanpa Penghilangan	
Derau dan Penghilangan Derau	180

4.9 Perbandingan Model Terbaik dengan Penelitian Sebelumnya	180
BAB V KESIMPULAN	182
DAFTAR PUSTAKA	184

DAFTAR GAMBAR

Gambar 2.1 Beat EKG	6
Gambar 2.2 Gelombang P	6
Gambar 2.3 Kompleks QRS	7
Gambar 2.4 Gelombang T	7
Gambar 2.5 Gelombang U	8
Gambar 2.6 Arsitektur Multilayer Perceptron	10
Gambar 2.7 Aktivasi Fungsi Sigmoid	11
Gambar 2.8 Aktivasi Fungsi Tanh	12
Gambar 2.9 Arsitektur Deep Neural Network	16
Gambar 2.10 Arsitektur Autoencoder Sederhana	21
Gambar 3.1 Diagram Alur Penelitian	27
Gambar 3.2 Kerangka Kerja	28
Gambar 3.3 Contoh Gambar Beat EKG	31
Gambar 3.4 Diagram Alur Normalisasi Minmax	33
Gambar 3.5 Diagram Alur Autoencoder	34
Gambar 3.6 Diagram Alur Deep Neural Network.....	36
Gambar 4.1 Hasil Segmentasi Beat EKG	40
Gambar 4.2 Hasil Sebelum dan Sesudah Normalisasi	40
Gambar 4.3 Grafik loss terhadap epoch Autoencoder 1 HL	42
Gambar 4.4 Hasil Reduksi Dimensi Encoder Autoencoder 1 HL	43
Gambar 4.5 Perbandingan Data Asli dengan Rekonstruksi AE	46
Gambar 4.6 Grafik loss terhadap Epoch Deep Autoencoder	47
Gambar 4.7 Hasil reduksi dimensi Deep Autoencoder	49
Gambar 4.8 Perbandingan Data Asli dengan Rekonstruksi Deep AE	51
Gambar 4.9 Grafik Loss dan Akurasi Model AE 1 HL – MLP 1 HL	54
Gambar 4.10 Matriks Konfusi Data Latih AE 1 HL -MLP 1 HL.....	55
Gambar 4.11 Matriks Konfusi Data Uji AE 1 HL -MLP 1 HL.....	55
Gambar 4.12 Kurva ROC pada Data Uji AE 1 HL – MLP 1 HL	58
Gambar 4.13 Kurva P-R pada Data Uji AE 1 HL – MLP 1 HL	59

Gambar 4.14 Grafik Loss dan Akurasi Model Deep AE – MLP 1 HL ..	60
Gambar 4.15 Matriks Konfusi Data Latih Deep AE - MLP 1 HL	61
Gambar 4.16 Matriks Konfusi Data Uji Deep AE - MLP 1 HL.....	61
Gambar 4.17 Kurva ROC pada Data Uji Deep AE – MLP 1 HL.....	64
Gambar 4.18 Kurva P-R pada Data Uji Deep AE – MLP 1 HL	65
Gambar 4.19 Grafik loss dan akurasi model tanpa AE – MLP 1 HL ..	66
Gambar 4.20 Matriks Konfusi Data Latih tanpa AE - MLP 1 HL	67
Gambar 4.21 Matriks Konfusi Data Uji tanpa AE - MLP 1 HL.....	67
Gambar 4.22 Kurva ROC pada Data Uji Tanpa AE – MLP 1 HL	70
Gambar 4.23 Kurva P-R pada Data Uji Tanpa AE – MLP 1 HL	71
Gambar 4.24 Grafik Loss dan Akurasi Model Deep AE – MLP 2 HL ..	73
Gambar 4.25 Matriks Konfusi Data Latih AE 1 HL -MLP 2 HL.....	74
Gambar 4.26 Matriks Konfusi Data Uji AE 1 HL -MLP 2 HL.....	74
Gambar 4.27 Kurva ROC pada Data Uji AE 1 HL – MLP 2 HL	77
Gambar 4.28 Kurva P-R pada Data Uji AE 1 HL – MLP 2 HL	78
Gambar 4.29 Grafik Loss dan Akurasi Model Deep AE – MLP 2 HL ..	79
Gambar 4.30 Matriks Konfusi Data Latih Deep AE - MLP 2 HL	80
Gambar 4.31 Matriks Konfusi Data Uji Deep AE - MLP 2 HL.....	81
Gambar 4.32 Kurva ROC pada Data Uji Deep AE – MLP 2 HL.....	83
Gambar 4.33 Kurva P-R pada Data Uji Deep AE – MLP 2 HL	84
Gambar 4.34 Grafik loss dan akurasi model tanpa AE – MLP 2 HL ..	85
Gambar 4.35 Matriks Konfusi Data Latih tanpa AE - MLP 2 HL	86
Gambar 4.36 Matriks Konfusi Data Uji tanpa AE - MLP 2 HL.....	86
Gambar 4.37 Kurva ROC pada Data Uji Tanpa AE – MLP 2 HL	89
Gambar 4.38 Kurva P-R pada Data Uji Tanpa AE – MLP 2 HL	90
Gambar 4.39 Grafik Loss dan Akurasi Model AE 1 HL – DNN 3 HL ..	92
Gambar 4.40 Matriks Konfusi Data Latih AE 1 HL - DNN 3 HL	93
Gambar 4.41 Matriks Konfusi Data Uji AE 1 HL - DNN 3 HL	93
Gambar 4.42 Kurva ROC pada Data Uji AE 1 HL – DNN 3 HL	96
Gambar 4.43 Kurva P-R pada Data Uji AE 1 HL – DNN 3 HL	97
Gambar 4.44 Grafik Loss dan Akurasi Model Deep AE – DNN 3 HL ..	98
Gambar 4.45 Matriks Konfusi Data Latih Deep AE - DNN 3 HL	99

Gambar 4.46 Matriks Konfusi Data Uji Deep AE - DNN 3 HL	99
Gambar 4.47 Kurva ROC pada Data Uji Deep AE – DNN 3 HL	102
Gambar 4.48 Kurva P-R pada Data Uji Deep AE – DNN 3 HL	103
Gambar 4.49 Grafik loss dan akurasi model tanpa AE – DNN 3 HL ..	104
Gambar 4.50 Matriks Konfusi Data Latih tanpa AE - DNN 3 HL.....	105
Gambar 4.51 Matriks Konfusi Data Uji tanpa AE - DNN 3 HL	105
Gambar 4.52 Kurva ROC pada Data Uji Tanpa AE – DNN 3 HL.....	108
Gambar 4.53 Kurva P-R pada Data Uji Tanpa AE – DNN 3 HL	109
Gambar 4.54 Grafik Loss dan Akurasi Model AE 1 HL – DNN 4 HL	111
Gambar 4.55 Matriks Konfusi Data Latih AE 1 HL - DNN 4 HL	112
Gambar 4.56 Matriks Konfusi Data Uji AE 1 HL - DNN 4 HL	112
Gambar 4.57 Kurva ROC pada Data Uji AE 1 HL – DNN 4 HL	115
Gambar 4.58 Kurva P-R pada Data Uji AE 1 HL – DNN 4 HL	116
Gambar 4.59 Grafik Loss dan Akurasi Model Deep AE – DNN 4 HL	117
Gambar 4.60 Matriks Konfusi Data Latih Deep AE - DNN 4 HL	118
Gambar 4.61 Matriks Konfusi Data Uji Deep AE - DNN 4 HL	119
Gambar 4.62 Kurva ROC pada Data Uji Deep AE – DNN 4 HL	121
Gambar 4.63 Kurva P-R pada Data Uji Deep AE – DNN 4 HL	122
Gambar 4.64 Grafik loss dan akurasi model tanpa AE – DNN 4 HL ..	123
Gambar 4.65 Matriks Konfusi Data Latih tanpa AE - DNN 4 HL.....	124
Gambar 4.66 Matriks Konfusi Data Uji tanpa AE – DNN 4 HL	124
Gambar 4.67 Kurva ROC pada Data Uji Tanpa AE – DNN 4 HL.....	127
Gambar 4.68 Kurva P-R pada Data Uji Tanpa AE – DNN 4 HL	128
Gambar 4.69 Grafik Loss dan Akurasi Model AE 1 HL – DNN 5 HL	130
Gambar 4.70 Matriks Konfusi Data Latih AE 1 HL - DNN 5 HL	131
Gambar 4.71 Matriks Konfusi Data Uji AE 1 HL - DNN 5 HL	131
Gambar 4.72 Kurva ROC pada Data Uji AE 1 HL – DNN 5 HL	134
Gambar 4.73 Kurva P-R pada Data Uji AE 1 HL – DNN 5 HL	135
Gambar 4.74 Grafik Loss dan Akurasi Model Deep AE – DNN 5 HL	136
Gambar 4.75 Matriks Konfusi Data Latih Deep AE - DNN 5 HL.....	137
Gambar 4.76 Matriks Konfusi Data Uji Deep AE - DNN 5 HL	137
Gambar 4.77 Kurva ROC pada Data Uji Deep AE – DNN 5 HL	140

Gambar 4.78 Kurva P-R pada Data Uji Deep AE – DNN 5 HL	141
Gambar 4.79 Grafik loss dan akurasi model tanpa AE – DNN 5 HL ..	142
Gambar 4.80 Matriks Konfusi Data Latih tanpa AE - DNN 5 HL.....	143
Gambar 4.81 Matriks Konfusi Data Uji tanpa AE – DNN 5 HL	143
Gambar 4.82 Kurva ROC pada Data Uji Tanpa AE – DNN 5 HL.....	146
Gambar 4.83 Kurva P-R pada Data Uji Tanpa AE – DNN 5 HL	147
Gambar 4.84 Perbandingan boxplot evaluasi data uji	149
Gambar 4.85 Grafik loss dan akurasi Generalisasi fitur dataset IncartDB	151
Gambar 4.86 Matriks Konfusi Data Latih Generalisasi fitur dataset IncartDB	152
Gambar 4.87 Matriks Konfusi Data Uji Generalisasi fitur dataset IncartDB	152
Gambar 4.88 Kurva ROC Generalisasi Fitur Dataset IncartDB	154
Gambar 4.89 Kurva P-R Generalisasi Fitur Dataset IncartDB	155
Gambar 4.90 Grafik loss dan akurasi Generalisasi fitur dataset SVDB	156
Gambar 4.91 Matriks Konfusi Data Latih Generalisasi fitur dataset SVDB.....	157
Gambar 4.92 Matriks Konfusi Data Uji Generalisasi fitur dataset SVDB.....	157
Gambar 4.93 Kurva ROC Generalisasi Fitur Dataset SVDB	159
Gambar 4.94 Kurva P-R Generalisasi Fitur Dataset SVDB	160
Gambar 4.95 Grafik loss dan akurasi Pengujian Klasifikasi dengan penghilangan derau pada dataset IncartDB	162
Gambar 4.96 Matriks Konfusi Data Latih Penghilangan Derau dataset IncartDB	163
Gambar 4.97 Matriks Konfusi Data Latih Penghilangan Derau dataset IncartDB	163
Gambar 4.98 Kurva ROC Klasifier dengan Penghilangan Derau pada dataset IncartDB	165
Gambar 4.99 Kurva P-R Klasifier dengan Penghilangan Derau pada dataset IncartDB	166

Gambar 4.100 Grafik loss dan akurasi Pengujian Klasifikasi dengan penghilangan derau pada dataset SVDB	167
Gambar 4.101 Matriks Konfusi Data Latih Penghilangan Derau dataset SVDB.....	168
Gambar 4.102 Matriks Konfusi Data Latih Penghilangan Derau dataset SVDB.....	168
Gambar 4.103 Kurva ROC Klasifier dengan Penghilangan Derau pada dataset SVDB	181
Gambar 4.104 Kurva P-R Klasifier dengan Penghilangan Derau pada dataset SVDB	181

DAFTAR TABEL

Tabel 1. Matriks konfusi klasifikasi multi kelas	22
Tabel 2. Penomoran label anotasi beat yang digunakan	29
Tabel 3. Jumlah beat pada setiap anotasi	30
Tabel 4. Jumlah beat pada dataset IncartDB dan SVDB	32
Tabel 5. Arsitektur Autoencoder 1 Hidden Layer	41
Tabel 6. Arsitektur Deep Autoencoder	46
Tabel 7. Arsitektur MLP 1 HL	53
Tabel 8. Jumlah TP, FP, FN, dan TN Data Latih AE 1 HL – MLP 1 HL	56
Tabel 9. Jumlah TP, FP, FN, dan TN Data Uji AE 1 HL – MLP 1 HL	56
Tabel 10. Evaluasi Data Latih AE 1 HL – MLP 1 HL	59
Tabel 11. Evaluasi Data Uji AE 1 HL – MLP 1 HL	59
Tabel 12. Jumlah TP, FP, FN, dan TN Data Latih Deep AE – MLP 1 HL	62
Tabel 13. Jumlah TP, FP, FN, dan TN Data Uji Deep AE – MLP 1 HL	62
Tabel 14. Evaluasi Data Latih Deep AE 1 HL – MLP 1 HL	63
Tabel 15. Evaluasi Data Uji Deep AE 1 HL – MLP 1 HL	63
Tabel 16. Jumlah TP, FP, FN, dan TN Data Latih Tanpa AE – MLP 1 HL	67
Tabel 17. Jumlah TP, FP, FN, dan TN Data Uji AE 1 HL – MLP 1 HL	67
Tabel 18. Evaluasi Data Latih Model AE 1 HL – MLP 1 HL	69
Tabel 19. Evaluasi Data Uji Model AE 1 HL – MLP 1 HL	69
Tabel 20. Arsitektur MLP 2 HL	72
Tabel 21. Jumlah TP, FP, FN, dan TN Data Latih AE 1 HL – MLP 2 HL	75
Tabel 22. Jumlah TP, FP, FN, dan TN Data Uji AE 1 HL – MLP 2 HL	75

Tabel 23. Evaluasi Data Latih AE 1 HL – MLP 2 HL	76
Tabel 24. Evaluasi Data Uji AE 1 HL – MLP 2 HL	76
Tabel 25. Jumlah TP, FP, FN, dan TN Data Latih Deep AE – MLP 2 HL	81
Tabel 26. Jumlah TP, FP, FN, dan TN Data Uji Deep AE– MLP 2 HL	81
Tabel 27. Evaluasi Data Latih Deep AE 1 HL – MLP 2 HL	82
Tabel 28. Evaluasi Data Uji Deep AE 1 HL – MLP 2 HL	82
Tabel 29. Jumlah TP, FP, FN, dan TN Data Latih Tanpa AE – MLP 2 HL	87
Tabel 30. Jumlah TP, FP, FN, dan TN Data Uji Tanpa AE – MLP 2 HL	87
Tabel 31. Evaluasi Data Latih Model Tanpa AE – MLP 2 HL	88
Tabel 32. Evaluasi Data Uji Model Tanpa AE – MLP 2 HL	88
Tabel 33. Arsitektur DNN 3 HL	91
Tabel 34. Jumlah TP, FP, FN, dan TN Data Latih AE 1 HL – DNN 3 HL	94
Tabel 35. Jumlah TP, FP, FN, dan TN Data Uji AE 1 HL – DNN 3 HL.....	94
Tabel 36 Evaluasi Data Latih AE 1 HL – DNN 3 HL	95
Tabel 37. Evaluasi Data Uji AE 1 HL – DNN 3 HL	95
Tabel 38. Jumlah TP, FP, FN, dan TN Data Latih Deep AE – DNN 3 HL	100
Tabel 39. Jumlah TP, FP, FN, dan TN Data Uji Deep AE– DNN 3 HL.....	100
Tabel 40. Evaluasi Data Latih Deep AE 1 HL – DNN 3 HL	101
Tabel 41. Evaluasi Data Uji Deep AE 1 HL – DNN 3 HL	101
Tabel 42. Jumlah TP, FP, FN, dan TN Data Latih Tanpa AE – DNN 3 HL	106
Tabel 43. Jumlah TP, FP, FN, dan TN Data Uji Tanpa AE – DNN 3 HL.....	106
Tabel 44. Evaluasi Data Latih Model Tanpa AE – DNN 3 HL	107

Tabel 45. Evaluasi Data Uji Model Tanpa AE – DNN 3 HL	107
Tabel 46. Arsitektur DNN 4 HL	110
Tabel 47. Jumlah TP, FP, FN, dan TN Data Latih AE 1 HL – DNN 4 HL	113
Tabel 48. Jumlah TP, FP, FN, dan TN Data Uji AE 1 HL – DNN 4 HL.....	113
Tabel 49. Evaluasi Data Latih AE 1 HL – DNN 4 HL	114
Tabel 50. Evaluasi Data Uji AE 1 HL – DNN 4 HL	114
Tabel 51. Jumlah TP, FP, FN, dan TN Data Latih Deep AE – DNN 4 HL	119
Tabel 52. Jumlah TP, FP, FN, dan TN Data Uji Deep AE– DNN 4 HL.....	119
Tabel 53. Evaluasi Data Latih Deep AE 1 HL – DNN 4 HL	120
Tabel 54. Evaluasi Data Uji Deep AE 1 HL – DNN 4 HL	120
Tabel 55. Jumlah TP, FP, FN, dan TN Data Latih Tanpa AE – DNN 4 HL	125
Tabel 56. Jumlah TP, FP, FN, dan TN Data Uji Tanpa AE – DNN 4 HL.....	125
Tabel 57. Evaluasi Data Latih Model Tanpa AE – DNN 4 HL	126
Tabel 58. Evaluasi Data Uji Model Tanpa AE – DNN 4 HL	126
Tabel 59. Arsitektur DNN 5 HL	129
Tabel 60. Jumlah TP, FP, FN, dan TN Data Latih AE 1 HL – DNN 5 HL	132
Tabel 61. Jumlah TP, FP, FN, dan TN Data Uji AE 1 HL – DNN 5 HL.....	132
Tabel 62. Evaluasi Data Latih AE 1 HL – DNN 5 HL	133
Tabel 63. Evaluasi Data Uji AE 1 HL – DNN 5 HL	133
Tabel 64. Jumlah TP, FP, FN, dan TN Data Latih Deep AE – DNN 5 HL	138
Tabel 65. Jumlah TP, FP, FN, dan TN Data Uji Deep AE– DNN 5 HL.....	138
Tabel 66. Evaluasi Data Latih Deep AE 1 HL – DNN 5 HL	139

Tabel 67. Evaluasi Data Uji Deep AE 1 HL – DNN 5 HL	139
Tabel 68. Jumlah TP, FP, FN, dan TN Data Latih Tanpa AE – DNN 5 HL	144
Tabel 69. Jumlah TP, FP, FN, dan TN Data Uji Tanpa AE – DNN 5 HL.....	144
Tabel 70. Evaluasi Data Latih Model Tanpa AE – DNN 5 HL	145
Tabel 71. Evaluasi Data Uji Model Tanpa AE – DNN 5 HL	145
Tabel 72. Tabel Hasil Evaluasi Data Uji 15 Model	149
Tabel 73. Evaluasi Klasifier Data Latih Generalisasi Fitur Dataset IncartDB	153
Tabel 74. Evaluasi Klasifier Data Uji Generalisasi Fitur Dataset IncartDB	153
Tabel 75. Evaluasi Klasifier Data Latih Generalisasi Fitur Dataset SVDB	158
Tabel 76. Evaluasi Klasifier Data Uji Generalisasi Fitur Dataset SVDB	158
Tabel 77. Perbandingan Antar Dataset	161
Tabel 78. Evaluasi Klasifier dengan Penghilangan Derau pada Data Latih IncartDB	164
Tabel 79. Evaluasi Klasifier dengan Penghilangan Derau pada Data Uji IncartDB	164
Tabel 80. Evaluasi Klasifier dengan Penghilangan Derau pada Data Latih SVDB	168
Tabel 81. Evaluasi Klasifier dengan Penghilangan Derau pada Data Uji SVDB	168
Tabel 82. Perbandingan Hasil Generalisasi Fitur dengan Penghilangan Derau Dataset IncartDB dan SVDB	172
Tabel 83. Perbandingan terhadap penelitian sebelumnya	173

BAB I

PENDAHULUAN

1.1 LATAR BELAKANG

Penyakit jantung bertanggung jawab atas sekitar 17 juta kematian setiap tahun di dunia, sekitar 25% dikarenakan kematian serangan jantung mendadak [1]. Menurut data *The American College of Cardiology* (ACC) dan *American Heart Association* (AHA), kematian serangan jantung mendadak dipicu oleh aritmia jantung [1][2]. Aritmia jantung merupakan masalah irama jantung yang terjadi ketika impuls listrik yang mengkoordinasikan detak jantung tidak berfungsi dengan baik, sehingga menyebabkan jantung berdetak terlalu cepat, terlalu lambat atau tidak teratur.

Diagnosis aritmia jantung di dunia medis saat ini masih menggunakan teknologi *non-invasive*, yaitu elektrokardiogram. Elektrokardiogram (EKG) merupakan serangkaian pengujian untuk pemeriksaan kondisi jantung dalam bentuk representatif sinyal listrik yang dapat menunjukkan informasi klinis mengenai jantung pasien [3]. Dalam mendiagnosis aritmia jantung, ada dua kategori penting saat merepresentasikan sinyal listrik yang berisi informasi, yaitu detak (*beat*) dan ritme jantung yang merupakan sekumpulan dari detak jantung [4]. Diagnosis aritmia jantung membutuhkan peranan tenaga medis untuk menghasilkan interpretasi EKG yang akurat.

Sayangnya, diagnosis aritmia jantung secara manual sering menyebabkan suatu masalah bagi kardiologis dalam merepresentasikan sinyal EKG [5]. Durasi perekaman yang lama, variasi morfologi fitur dan kecilnya amplitude yang sulit

dibedakan dengan mata serta memungkinkan terjadinya kesalahan (*human error*) dalam analisa perekaman EKG yang sangat lama karena kelelahan [6].

Diagnosis aritmia jantung secara otomatis melalui morfologi bentuk detak jantung (beat) saat menganalisis sinyal EKG telah banyak dikembangkan dalam beberapa penelitian dengan menggunakan metode *machine learning* (pembelajaran mesin), Qin et. al [7] mengimplementasikan metode Wavelet Transform dan *Principal Component Analysis* (PCA) untuk mereduksi fitur kemudian diklasifikasi oleh algoritma *Support Vektor Machine* (SVM) untuk mengklasifikasikan beat pada sinyal EKG dan menghasilkan performa rata-rata akurasi 99.7%, *Sensitivitas* 99.09%, dan *Spesifisitas* 99.82%. Namun, hanya enam jenis tipe beats pada aritmia jantung yang diklasifikasi, yaitu *Atrial Premature Beat* (A), *Left Bundle Branch Block* (L), *Normal Beat* (N), *Paced Beat* (P), *Right Bundle Branch Block Beat* (R) and *Premature ventricular Contraction* (V).

Saat ini telah berkembang metode pembelajaran terawasi (*supervised learning*) dengan *deep learning*, dimana fitur dipelajari oleh secara otomatis, tanpa perlu mengekstraksi fitur campur tangan manusia [8]. Deep learning dapat belajar dengan tingkat abstraksi yang lebih tinggi dari metode pembelajaran mesin sebelumnya dengan struktur yang berlapis-lapis serta mendalam [9] namun masih sedikit penelitian yang dilakukan mengenai klasifikasi beat EKG secara *deep learning*. Rahhal, et al [10] mengimplementasikan pendekatan *deep learning* dengan menggunakan *Autoencoder* untuk mereduksi dimensi fitur EKG kemudian mengklasifikasikan beat EKG menggunakan *Deep Neural Network* dengan meraih performa yang lebih baik ketimbang model neural network umumnya. Namun, hanya terbatas pada 4 kelas beat saja (N,S,V, dan F) yang diklasifikasikan.

Berdasarkan penelitian sebelumnya mengenai klasifikasi beat EKG secara deep learning menggunakan *Autoencoder* dan *Deep Neural Network*, penulis akan menggunakan metode yang sama yakni *Autoencoder* dan *Deep Neural Network* namun mengklasifikasi kelas yang lebih banyak yakni 10 kelas.

1.2 Tujuan

Adapun tujuan dilakukannya penelitian ini adalah :

1. Membuat model dengan arsitektur *Deep Learning* untuk mengklasifikasi sinyal EKG
2. Menguji dan menvalidasi model yang telah dipilih.

1.3 Perumusan Masalah

Berdasarkan latar belakang yang telah dikemukakan , maka rumusan masalah yang ada pada tugas akhir ini adalah :

1. Penelitian ini menggunakan data dari *MIT-BIH Arrhythmia Database*.
2. Pengklasifikasian beat EKG hanya dilakukan terhadap 10 kelas, yaitu *Atrial Premature Beat, Left Bundle Branch Block, Normal Beat, Paced Beat, Right Bundle Branch Block, Premature Ventricular Contraction, Fusion of paced and normal beat, Fusion of Ventricular and Normal Beat, Ventricular Flutter Wave, Nodal (junctional) Escape Beat*.
3. Derau pada sinyal EKG inputan tidak dihilangkan
4. Penelitian ini hanya sebatas simulasi program dengan menggunakan bahasa pemrograman Python untuk membuat model *Deep Learning* untuk pengklasifikasian 10 kelas beat EKG dengan *Autoencoder* dan *Deep Neural Network*.

1.4 Sistematika Penulisan

Sistematika yang akan digunakan dalam penulisan tugas akhir ini akan melewati beberapa tahap sebagai berikut :

BAB I PENDAHULUAN

Pada bab pertama ini berisi tentang penjabaran secara sistematis topic yang diambil meliputi latar belakang, tujuan dan manfaat, perumusan dan batasan masalah, metodologi dan sistematika penulisan

BAB II TINJAUAN PUSTAKA

Pada bab kedua ini menjelaskan dasar teori yang menunjang pembahasan dari penelitian ini. Dasar teori ini berisi tentang literature EKG, gelombang EKG, beat EKG, neural network, dan autoencoder.

BAB III METODOLOGI PENELITIAN

Pada bab ketiga ini menjelaskan bagaimana penelitian ini berjalan dari persiapan data, pra-pemrosesan, pembagian data pelatihan dan pengujian, klasifikasi, serta validasi.

BAB IV PEMBAHASAN

Pada bab keempat ini menjelaskan hasil dan analisa terhadap penelitian yang telah dilakukan.

BAB V KESIMPULAN

Pada bab kelima ini menarik kesimpulan berdasarkan hasil dan analisa terhadap penelitian yang telah dilakukan

Daftar Pustaka

- [1] S. Mendis, P. Puska, B. Norrving, W. H. Organization, and others, *Global atlas on cardiovascular disease prevention and control*. Geneva: World Health Organization, 2011.
- [2] T. P. Nguyen, Z. Qu, and J. N. Weiss, “Cardiac fibrosis and arrhythmogenesis: the road to repair is paved with perils,” *Journal of molecular and cellular cardiology*, vol. 70, pp. 83–91, 2014.

- [3] J. R. Hampton, *The ECG Made Easy*, 8th ed. Elsevier Ltd, 2013.
- [4] G. Tse, “Mechanisms of cardiac arrhythmias,” *Journal of Arrhythmia*, vol. 32, no. 2, pp. 75–81, 2016.
- [5] M. G. Khan, *Rapid ECG interpretation*. Springer Science & Business Media, 2008.
- [6] A. P. Shah and S. A. Rubin, “Errors in the computerized electrocardiogram interpretation of cardiac rhythm,” *Journal of electrocardiology*, vol. 40, no. 5, pp. 385–390, 2007.
- [7] Q. Qin, J. Li, L. Zhang, Y. Yue, and C. Liu, “Combining Low-dimensional Wavelet Features and Support Vektor Machine for Arrhythmia Beat Classification,” *Scientific Reports*, vol. 7, no. 1, pp. 1–12, 2017.
- [8] T. Wiatowski and H. Bolcskei, “A Mathematical Theory of Deep Convolutional Neural Networks for Feature Extraction,” *IEEE Transactions on Information Theory*, vol. 64, no. 3, pp. 1845–1866, 2018.
- [9] L. Deng, “Deep Learning: Methods and Applications,” *Foundations and Trends® in Signal Processing*, vol. 7, no. 3–4, pp. 197–387, 2014.
- [10] M. M. A. Rahhal, Y. Bazi, H. Alhichri, N. Alajlan, F. Melgani, and R. R. Yager, “Deep learning approach for active classification of electrocardiogram signals,” *Information Sciences*, vol. 345, no. March, pp. 340–354, 2016.
- [11] C. A. Goudis, A. K. Konstantinidis, I. V. Ntalas, and P. Korantzopoulos, “Electrocardiographic abnormalities and cardiac arrhythmias in chronic obstructive pulmonary disease,” *International Journal of Cardiology*, vol. 199, pp. 264–273, 2015.
- [12] T. Okabe and S. J. Kalbfleisch, “Cardiac Arrhythmia in Heart Failure,” in *Encyclopedia of Cardiovascular Research and Medicine*, Elsevier Inc., 2018, pp. 394–410.

- [13] H. V. Huikuri, A. Castellanos, and R. J. Myerburg, “Sudden death due to Cardiac Arrhythmias,” *New England Journal of Medicine*, vol. 345, no. 20, pp. 1473–1482, 2001.
- [14] T. B. Garcia, *12-Lead ECG : The Art of Interpretation*, 2nd ed. Jones & Bartlett Learning, 2015.
- [15] P. C. Chang, J. J. Lin, J. C. Hsieh, and J. Weng, “Myocardial infarction classification with multi-lead ECG using hidden Markov models and Gaussian mixture models,” *Applied Soft Computing Journal*, vol. 12, no. 10, pp. 3165–3175, 2012.
- [16] R. Singh and J. J. Murphy, “Electrocardiogram and arrhythmias,” *Anaesthesia and Intensive Care Medicine*, vol. 19, no. 6, pp. 322–325, 2018.
- [17] A. L. Goldberger *et al.*, “PhysioBank, PhysioToolkit, and PhysioNet Components of a New Research Resource for Complex Physiologic Signals,” *Circulation*, vol. 101, no. 23, 2000.
- [18] F. Amato, A. López, E. M. Peña-méndez, P. Vaňhara, and A. Hampl, “Artificial neural networks in medical diagnosis,” *Journal of APPLIED BIOMEDICINE*, vol. 11, pp. 47–58, 2013.
- [19] S. Samarasinghe, *Neural Networks for Applied Sciences and Engineering : From Fundamentals to Complex Pattern Recognition*. Auerbach Publications, 2006.
- [20] M. A. Nielsen, *Neural Networks and Deep Learning*. Determination Press, 2015.
- [21] J. Patterson and A. Gibson, *Deep Learning: A Practitioner’s Approach*, 1th ed. O’Reilly Media, Inc., 2017.
- [22] B. Xu, R. Huang, and M. Li, “Revise Saturated Activation Functions,” *International Conference on Learning Representations*, pp. 1–7, 2016.

- [23] A. L. Maas, A. Y. Hannun, and A. Y. Ng, “Rectifier Nonlinearities Improve Neural Network Acoustic Models,” in *Proceedings of the 30th International Conference on Machine Learning*, 2013, vol. 28.
- [24] R. H. R. Hahnloser, “Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit,” *Nature*, vol. 442, no. 1998, pp. 947–951, 2000.
- [25] K. Jarrett, K. Kavukcuoglu, M. A. Ranzato, and Y. Lecun, “What is the Best Multi-Stage Architecture for Object Recognition ?,” *IEEE International Conference on Computer Vision*, vol. 12, 2009.
- [26] G. E. Hinton and V. Nair, “Rectified Linear Units Improve Restricted Boltzmann Machines,” in *Proceedings of the 27th International Conference on Machine Learning*, 2010.
- [27] X. Glorot, A. Bordes, and Y. Bengio, “Deep Sparse Rectifier Neural Networks,” in *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*, 2011, vol. 15, pp. 315–323.
- [28] A. Courville, Y. Bengio, and I. Goodfellow, *Deep Learning*. MIT Press, 2016.
- [29] S. Ruder, “An overview of gradient descent optimization algorithms,” pp. 1–14, Sep. 2016.
- [30] G. Sannino and G. De Pietro, “A deep learning approach for ECG-based heartbeat classification for arrhythmia detection,” *Future Generation Computer Systems*, vol. 86, pp. 446–455, 2018.
- [31] Y. Bengio and O. Delalleau, “On the Expressive Power of Deep Architectures,” *Lecture Notes in Computer Sciences*, vol. 6925, pp. 18–36, 2011.
- [32] D. . Rumelhart, G. E. Hinton, and R. J. Williams, “Learning Internal Representation by Error Propagation,” in *Parallel Distributed Processing. Vol 1: Foundations.*, vol. 1, MIT Press, 1986, pp. 318–361.

- [33] Y. Bengio and Y. Lecun, “Scaling Learning Algorithms towards AI,” in *Large-Scale Kernel Machines*, no. 1, MIT Press, 2007, pp. 1–41.
- [34] D. Erhan, A. Courville, and P. Vincent, “Why Does Unsupervised Pre-training Help Deep Learning ?,” *Journal of Machine Learning Research*, vol. 11, pp. 625–660, 2010.
- [35] P. Baldi, “Autoencoders , Unsupervised Learning , and Deep Architectures,” *Journal of Machine Learning Research: Workshop and Conference Proceedings*, vol. 27, pp. 37–50, 2012.
- [36] G. E. Hinton and R. R. Salakhutdinov, “Reducing the Dimensionality of Data with Neural Networks,” *Science*, vol. 313, no. July, pp. 504–507, 2006.
- [37] A. Abid, M. Fatih, and B. James, “Concrete Autoencoders for Differentiable Feature Selection and Reconstruction,” *International Conference on Machine Learning*, 2019.
- [38] M. Alrahal, Y. Bazi, N. Ammour, M. Zuair, and B. Benjdira, “Convolutional Neural Networks for Electrocardiogram Classification,” *Journal of Medical and Biological Engineering*, vol. 38, no. 6, pp. 1014–1025, 2018.
- [39] O. Yildirim, U. B. Baloglu, R. S. Tan, E. J. Ciaccio, and U. R. Acharya, “A new approach for arrhythmia classification using deep coded features and LSTM networks,” *Computer Methods and Programs in Biomedicine*, vol. 176, pp. 121–133, 2019.
- [40] R. Li *et al.*, “ECG Beat Classification Based on Deep Bidirectional Long Short-Term Memory Recurrent Neural Network,” in *The International Conference on Healthcare Science and Engineering*, 2018, pp. 45–56.

