

**KLASIFIKASI 15 KELAS BEAT GANGGUAN
ARITMIA MENGGUNAKAN *AUTOENCODER* DAN
*DEEP NEURAL NETWORK***

TUGAS AKHIR

Diajukan Untuk Melengkapi Salah Satu Syarat

Memperoleh Gelar Sarjana Komputer



OLEH :

Tomi Mandala Putra

09011281722076

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

2021

LEMBAR PENGESAHAN

**KLASIFIKASI 15 KELAS BEAT GANGGUAN ARITMIA
MENGUNAKAN *AUTOENCODER* DAN *DEEP NEURAL
NETWORK***

TUGAS AKHIR

**Program Studi Sistem Komputer
Jenjang S1**

Oleh

**Tomi Maudala Putra
09011281722076**

Indralaya, 7 Febuari 2021

Mengetahui,

Ketua Jurusan Sistem Komputer

Pembimbing Tugas Akhir



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

The image shows a handwritten signature in black ink over a blue circular stamp of Universitas Sriwijaya, Fakultas Ilmu Komputer, Jurusan Sistem Komputer.

HALAMAN PERSETUJUAN

Telah diuji dan lulus pada :

Hari : Senin

Tanggal : 27 September 2021

Tim Penguji :

1. Ketua : Sutarno, S.T., M.T.
2. Sekretaris : Rahmat Fadli Isnanto, M.Sc
3. Penguji : Firdaus, M.Kom.
4. Pembimbing : Prof. Dr. Ir. Siti Nurmaini, M.T.



Handwritten signatures of the examiners, each placed above a horizontal line. The first signature is for Sutarno, S.T., M.T. The second is for Rahmat Fadli Isnanto, M.Sc. The third is for Firdaus, M.Kom. The fourth is for Prof. Dr. Ir. Siti Nurmaini, M.T.

Mengetahui,
Ketua Jurusan Sistem Komputer



HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Tomi Mandala Putra
NIM : 09011281722076
Judul : Klasifikasi 15 Kelas Beat Gangguan Aritmia Menggunakan
Autoencoder dan Deep Neural Network.

Hasil Penyecekan *Software iThenticate/Turnitin* : 2 %

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, September 2021



Tomi Mandala Putra
NIM. 09011281722076

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Puji syukur Alhamdulillah penulis panjatkan atas kehadiran Allah SWT yang telah memberikan karunia dan rahmatnya, sehingga penulis dapat menyelesaikan penulisan Tugas Akhir ini yang berjudul “**Klasifikasi 15 Kelas Beat Gangguan Aritmia Menggunakan Autoencoder dan Deep Neural Network**”.

Dalam laporan ini penulis melakukan penelitian mengenai klasifikasi 15 kelas beat gangguan aritmia menggunakan Autoencoder (AE) dan Deep Neural Network (DNN) dengan disertai data-data yang diperoleh penulis saat melakukan pengujian. Penulis berharap kedepannya tulisan ini dapat digunakan bagi orang banyak dan menjadi bahan bacaan yang bermanfaat pada bidang Medis khususnya penyakit jantung dan elektrokardiogram

Pada kesempatan ini penulis ingin mengucapkan terima kasih kepada beberapa pihak atas ide dan saran serta bantuannya dalam menyelesaikan penulisan Oleh karena itu, penulis ingin mengucapkan rasa syukur kepada Allah SWT 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 Dr. Ir. H. Sukemi, M.T., selaku Ketua Jurusan Sistem Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.
4. Ibu Prof. Dr. Ir. Siti Nurmaini, M.T, selaku Dosen Pembimbing Tugas Akhir yang selalu memberikan saran dan motivasi serta bimbingan terbaik untuk penulis dalam menyelesaikan Tugas Akhir ini.
5. Dr.Erwin, S.SI, M.SI, selaku Pembimbing Akademik Jurusan Sistem Komputer.

6. Seluruh bapak/ibu dosen yang ada di Jurusan Sistem Komputer.
7. Mbak Nisa, yang turut membantu memberikan arahan serta nasihat dalam pembuatan tugas akhir.
8. Teman – teman seperjuangan di Bedeng Kades (Topik, Defrian, Ahmad, Abi, Faiz, Wais, Xosya, Hafiz, Fadil)
9. Teman – teman dari Jurusan Sistem Komputer yang tidak bisa disebutkan satu persatu
10. Dan semua pihak yang telah membantu secara langsung maupun tidak langsung

Penulis menyadari bahwa Laporan ini masih sangat jauh dari kata sempurna. Untuk itu kritik dan saran yang membangun sangatlah diharapkan penulis agar dapat segera diperbaiki sehingga laporan ini dapat dijadikan sebagai masukan ide dan pemikiran yang bermanfaat bagi semua pihak dan menjadi tambahan bahan bacaan bagi yang tertarik dalam penelitian pada bidang Medis khususnya penyakit jantung dan elektrokardiogram.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Indralaya, 7 Febuari 2021

Penulis,

Tomi Mandala Putra

NIM. 09011281722076

KLASIFIKASI 15 KELAS BEAT GANGGUAN ARITMIA MENGUNAKAN AUTOENCODER DAN DEEP NEURAL NETWORK

TOMI MANDALA PUTRA (09011281722076)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

Email: tommyxm99@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. Penelitian ini mendapatkan hasil pada 48 record model terbaik lebih unggul dengan menggunakan *Learning rate* 0.0001 dengan pembagian baik pada *train test split* dengan nilai akurasi 99.82% dan *Stratified K-Fold* dengan nilai akurasi 99.83%.

Kata kunci : *Aritmia, Elektrokardiografi, Klasifikasi, Autoencoder, Deep Neural Network.*

CLASSIFICATION OF 15 CLASS OF BEAT ARRHYTHMIA DISORDERS USING AUTOENCODER AND DEEP NEURAL NETWORK

TOMI MANDALA PUTRA (09011281722076)

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

Email: tommyxm99@gmail.com

ABSTRACT

Electrocardiography (ECG) is a medical test to examine the condition of the heart in a representation of electrical signals that provide clinical information about the patient's heart. With ECG, cardiologists are able to diagnose the patient's heart condition either by heart rate or heart rhythm. ECG beat classification with a large amount of data has its own challenges, so the Deep Learning method which has a high level of abstraction in studying features is highly superior. With the Autoencoder method as feature extraction to study features and reduce feature dimensions and Deep Neural Network as an ECG beat classifier. This study found that 48 records of the best model were superior using a Learning rate of 0.0001 with a good division on the train test split with an accuracy value of 99.82% and Stratified K-Fold with an accuracy value of 99.83%.

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

DAFTAR ISI

	Halaman
LEMBAR PENGESAHAN	ii.
HALAMAN PERSETUJUAN	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI	ix
DAFTAR GAMBAR	xii
DAFTAR TABEL	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2. Tujuan	2
1.3 Perumusan Masalah	3
1.4 Sistematika Penulisan	3
BAB II TINJAUAN PUSTAKA	5
2.1 Elektrokardiogram	5
2.2 Gelombang EKG	5
2.3 Aritmia	6
2.4 Discrete Wavelet Transform (DWT)	6
2.5 Autoencoder (AE).....	8
2.6 <i>Stratified K-Fold</i>	9
2.7 Deep Neural Network (DNN)	9
2.8 Model Evaluasi	13
2.8.1 Akurasi	14
2.8.2 Spesifisitas.....	15
2.8.3 Sensitifitas	15
2.8.4 Presisi.....	15
2.8.5 <i>F1-Score</i>	16

BAB III METODOLOGI PENELITIAN	17
3.1 Pendahuluan	17
3.2 Kerangka Kerja.....	17
3.3 MIT-BIH Arrhythmia Database	19
3.4 Akuisisi Data	19
3.5 Normalisasi.....	24
3.6 Membuat Sinyal Target.....	25
3.7 Segmentasi	26
3.8 AE	27
3.9 Klasifikasi	28
3.9.1 Pembagian Data	28
3.9.2 DNN	29
3.10 Evaluasi Hasil.....	30
BAB IV HASIL DAN PEMBAHASAN.....	31
4.1 Pendahuluan	31
4.2 Hasil Normalisasi Sinyal.....	31
4.3 Hasil DWT	32
4.4 Hasil Segmentasi Sinyal.....	34
4.5 Hasil Autoencoder	37
4.6 Hasil DNN.....	39
4.6.1 Hasil Klasifikasi dengan Model 1 DNN	40
4.6.2 Hasil Klasifikasi dengan Model 2 DNN	41
4.6.3 Hasil Klasifikasi dengan Model 3 DNN	43
4.6.4 Hasil Klasifikasi dengan Model 4 DNN	45
4.6.5 Hasil Klasifikasi dengan Model 5 DNN	47
4.6.6 Hasil Klasifikasi dengan Model 6 DNN	49
4.6.7 Hasil Klasifikasi dengan Model 7 DNN	51
4.6.8 Hasil Klasifikasi dengan Model 8 DNN	53
4.6.9 Perbandingan Hasil dari Keseluruhan 8 Model DNN pada <i>Train test split</i> 55	
4.6.10 Hasil Klasifikasi dengan Pembagian Data <i>Stratified K-Fold</i> pada <i>Learning Rate</i> 0.0001085.....	56
4.6.11 Hasil Klasifikasi dengan Pembagian Data <i>Stratified K-Fold</i> pada <i>Learning Rate</i> 0.0001.....	61

4.7	Pengujian Unseen Berbasis <i>Best Architecture</i> DNN.....	66
4.7.1	Hasil Performa AE dari <i>Best Architecture AE</i>	67
4.7.2	Hasil Performa DNN pada Model 9 Menggunakan <i>Train test split</i> 70	
4.7.3	Hasil Performa DNN pada Model 10 pada <i>Train test split</i>	72
4.7.4	Hasil Performa DNN dari <i>Best Architecture</i> DNN pada <i>Learning Rate</i> 0.0001 Menggunakan <i>Stratified K-Fold</i>	75
4.7.5	Hasil Performa DNN dari <i>Best Architecture</i> DNN pada <i>Learning Rate</i> 0.0001085 Menggunakan <i>Stratified K-Fold</i>	78
4.8	Hasil Pengujian <i>Unseen</i> Menggunakan Performa Model 9	81
4.9	Hasil Pengujian <i>Unseen</i> Menggunakan Performa Model 10	83
4.10	Hasil Pengujian <i>Unseen</i> Menggunakan Performa Best Folder Model Pada Pengujian 4.7.4	85
4.11	Hasil Pengujian <i>Unseen</i> Menggunakan Performa Best Folder Model Pada Pengujian 4.7.5	87
4.12	Perbandingan Hasil dari Keseluruhan 10 Model DNN pada <i>Train test split</i> 89	
4.13	Perbandingan Hasil dari Keseluruhan Pengujian <i>Unseen</i>	90
BAB V KESIMPULAN DAN SARAN.....		91
5.1	Kesimpulan.....	91
5.2	Saran	92
DAFTAR PUSTAKA.....		93

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Beat EKG [3]	6
Gambar 2.2. Dekomposisi DWT [18]	7
Gambar 2.3. Proses <i>Autoencoder</i> secara sederhana [23].....	9
Gambar 2.4. Arsitektur Deep Neural Network	10
Gambar 3.1. Diagram alur penelitian	18
Gambar 3.2. Contoh gambar beat EKG	23
Gambar 3.3 Diagram alur normalisasi minmax	25
Gambar 3.4 Diagram alur AE	28
Gambar 4.1. Hasil sinyal sebelum normalisasi dan sesudah normalisasi	32
Gambar 4.2 Sampel Hasil DWT Beat EKG menggunakan sym 7	34
Gambar 4.3 Sampel Hasil Segmentasi Ke – 15 beats EKG yang digunakan .	36
Gambar 4.4 Loss Training AE Pada Model yang Diusulkan	37
Gambar 4.5 Sampel Hasil AE ke - 15 Beat EKG pada Encod Layer	39
Gambar 4.6 Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke - 1	40
Gambar 4.7. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke - 2	42
Gambar 4.8. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke - 3	44
Gambar 4.9. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke - 4	46

Gambar 4.10. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke -5	48
Gambar 4.11. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke - 6	50
Gambar 4.12. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke - 7	52
Gambar 4.13 Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke - 8	54
Gambar 4.14 Grafik Akurasi (Model acc) dan Grafik Loss (Model Loss) pada Folder 1 dari DNN Menggunakan <i>Stratified K-Fold</i> pada <i>Learning Rate</i> 0.0001085	57
Gambar 4.15. Grafik Akurasi (Model acc) dan Grafik Loss (Model Loss) pada Folder 10 dari DNN Menggunakan <i>Stratified K-Fold</i> pada <i>Learning Rate</i> 0.0001085	59
Gambar 4.16. Grafik Akurasi (Model acc) dan Grafik Loss (Model Loss) pada Folder 3 dari DNN Menggunakan <i>Stratified K-Fold</i> pada <i>Learning Rate</i> 0.0001	62
Gambar 4.17. Grafik Akurasi (Model acc) dan Grafik Loss (Model Loss) pada Folder 8 dari DNN Menggunakan <i>Stratified K-Fold</i> pada <i>Learning Rate</i> 0.0001	64
Gambar 4.18. Alur Kerja Pengujian Unseen	67
Gambar 4.19. Loss Training AE	68
Gambar 4.20. Sampel Hasil AE Ke-15 Beat EKG Pada Encod Layer	70
Gambar 4.21. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke – 9.....	70
Gambar 4.22. Grafik Kurva P – R Pada Model DNN Ke – 9.....	72
Gambar 4.23. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Model DNN ke – 10.....	73
Gambar 4.24. Grafik Kurva P – R Pada Model DNN Ke – 10.....	75

Gambar 4.25. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Folder 6 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001	76
Gambar 4.26. Grafik Kurva P-R Pada Folder 6 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001.....	78
Gambar 4.27. Grafik Akurasi (Model acc) dan Grafik Loss (Model loss) pada Folder 1 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001085	79
Gambar 4.28. Grafik Kurva P-R Pada Folder 1 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001085.....	81
Gambar 4.29. Grafik Kurva P-R Pada Pengujian <i>Unseen</i> Model Ke-9	83
Gambar 4.30. Grafik Kurva P-R Pada Pengujian <i>Unseen</i> Model Ke-10	85
Gambar 4.31. Grafik Kurva P-R Pada Pengujian <i>Unseen</i> Menggunakan Best Folder Model Pada Pengujian 4.7.4	87
Gambar 4.32. Grafik Kurva P-R Pada Pengujian <i>Unseen</i> Menggunakan Best Folder Model Pada Pengujian 4.7.5	89

DAFTAR TABEL

	Halaman
Tabel 2.1. <i>Sample Confusion Matrix</i> klasifikasi <i>multi class</i> di kelas 1	13
Tabel 3.1. Penomoran label anotasi beat yang digunakan	20
Tabel 3.2. Jumlah beat pada setiap anotasi	20
Tabel 3.3. Acuan <i>Benchmark</i> DWT	26
Tabel 3.4. Model AE yang diusulkan	27
Tabel 3.5. Pembagian data training dan data testing	29
Tabel 3.6. Pembagian data menggunakan <i>Stratified K-Fold</i>	29
Tabel 3.7. Model DNN yang diusulkan	30
Tabel 4.1. Hasil SNR pada setiap Fungsi Wavelet	32
Tabel 4.2. Hasil AE Pada Model yang Diusulkan	37
Tabel 4.3. <i>Confusion Matrix</i> Data <i>Training</i> Model 1 DNN	40
Tabel 4.4. <i>Confusion Matrix</i> Data <i>Testing</i> Model 1 DNN	41
Tabel 4.5. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 1 DNN	41
Tabel 4.6. <i>Confusion Matrix</i> Data <i>Training</i> Model 2 DNN	42
Tabel 4.7. <i>Confusion Matrix</i> Data <i>Testing</i> Model 2 DNN	43
Tabel 4.8. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 2 DNN	43
Tabel 4.9. <i>Confusion Matrix</i> Data <i>Training</i> Model 3 DNN	44
Tabel 4.10. <i>Confusion Matrix</i> Data <i>Testing</i> Model 3 DNN	45
Tabel 4.11. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 3 DNN	45
Tabel 4.12. <i>Confusion Matrix</i> Data <i>Training</i> Model 4 DNN	46

Tabel 4.13. <i>Confusion Matrix</i> Data <i>Testing</i> Model 4 DNN	47
Tabel 4.14. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 4 DNN	47
Tabel 4.15. <i>Confusion Matrix</i> Data <i>Training</i> Model 5 DNN	48
Tabel 4.16. <i>Confusion Matrix</i> Data <i>Testing</i> Model 5 DNN	49
Tabel 4.17. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 5 DNN	49
Tabel 4.18. <i>Confusion Matrix</i> Data <i>Training</i> Model 6 DNN	50
Tabel 4.19. <i>Confusion Matrix</i> Data <i>Testing</i> Model 6 DNN	51
Tabel 4.20. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 6 DNN	51
Tabel 4.21. <i>Confusion Matrix</i> Data <i>Training</i> Model 7 DNN	52
Tabel 4.22. <i>Confusion Matrix</i> Data <i>Testing</i> Model 7 DNN	53
Tabel 4.23. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 7 DNN	53
Tabel 4.24. <i>Confusion Matrix</i> Data <i>Training</i> Model 8 DNN	54
Tabel 4.25. <i>Confusion Matrix</i> Data <i>Testing</i> Model 8 DNN	55
Tabel 4.26. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 8 DNN	55
Tabel 4.27. Evaluasi Keseluruhan 8 Model DNN pada Train test split	56
Tabel 4.28. Evaluasi Keseluruhan DNN Menggunakan <i>Stratified K-Fold</i> Pada <i>Learning Rate</i> 0.0001085	56
Tabel 4.29. <i>Confusion Matrix</i> Data <i>Training</i> Pada Folder 1 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001085	58
Tabel 4.30. <i>Confusion Matrix</i> Data <i>Testing</i> Pada Folder 1 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001085	58
Tabel 4.31. Evaluasi Performa Data Pelatihan dan data Pengujian pada Folder 1 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001085 .	59

Tabel 4.32. <i>Confusion Matrix</i> Data <i>Training</i> Pada Folder 10 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001085	60
Tabel 4.33. <i>Confusion Matrix</i> Data <i>Testing</i> Pada Folder 10 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001085	60
Tabel 4.34. Evaluasi Performa Data Pelatihan dan data Pengujian pada Folder 10 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001085	61
Tabel 4.35. Evaluasi Keseluruhan DNN Menggunakan <i>Stratified K-Fold</i> Pada <i>Learning Rate</i> 0.0001	61
Tabel 4.36. <i>Confusion Matrix</i> Data <i>Training</i> Pada Folder 3 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001	63
Tabel 4.37. <i>Confusion Matrix</i> Data <i>Testing</i> Pada Folder 3 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001	63
Tabel 4.38. Evaluasi Performa Data Pelatihan dan data Pengujian pada Folder 3 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001	64
Tabel 4.39. <i>Confusion Matrix</i> Data <i>Training</i> Pada Folder 8 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001	65
Tabel 4.40. <i>Confusion Matrix</i> Data <i>Testing</i> Pada Folder 8 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001	65
Tabel 4.41. Evaluasi Performa Data Pelatihan dan data Pengujian pada Folder 8 dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning rate</i> 0.0001	66
Tabel 4.42. Pembagian Data Pada Uji Coba Unseen Best Architecture DNN dengan LR 0.0001	66
Tabel 4.43. <i>Best Architecture</i> DNN yang digunakan	67
Tabel 4.44. Hasil Performa AE.....	68
Tabel 4.45. <i>Confusion Matrix</i> Data <i>Training</i> Model 9 DNN	71
Tabel 4.46. <i>Confusion Matrix</i> Data <i>Testing</i> Model 9 DNN	71
Tabel 4.47. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 9 DNN	72

Tabel 4.48. <i>Confusion Matrix</i> Data Training Model 10 DNN	73
Tabel 4.49. <i>Confusion Matrix</i> Data Testing Model 10 DNN.....	74
Tabel 4.50. Evaluasi Performa Data Pelatihan dan Data Pengujian Model 10 DNN	74
Tabel 4.51. Evaluasi Keseluruhan DNN Menggunakan <i>Stratified K-Fold</i> Dengan <i>Learning Rate</i> 0.0001	75
Tabel 4.52. <i>Confusion Matrix</i> Data Training Pada Folder 6 Dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001	77
Tabel 4.53. <i>Confusion Matrix</i> Data Testing Pada Folder 6 Dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001.....	77
Tabel 4.54. Evaluasi Performa Data Pelatihan dan Data Pengujian Pada Folder 6 Dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001	78
Tabel 4.55. Evaluasi Keseluruhan DNN Menggunakan <i>Stratified K-Fold</i> Dengan <i>Learning Rate</i> 0.0001085	79
Tabel 4.56. <i>Confusion Matrix</i> Data Training Pada Folder 1 Dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001085.....	80
Tabel 4.57. <i>Confusion Matrix</i> Data Testing Pada Folder 1 Dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001085.....	80
Tabel 4.58. Evaluasi Performa Data Pelatihan dan Data Pengujian Pada Folder 1 Dari DNN Menggunakan <i>Stratified K-Fold</i> dengan <i>Learning Rate</i> 0.0001085	81
Tabel 4.59. <i>Confusion Matrix</i> Pada Pengujian <i>Unseen</i> Menggunakan Model 9	82
Tabel 4.60. Evaluasi Performa Pada Pengujian <i>Unseen</i> Menggunakan Model 9	82
Tabel 4.61. <i>Confusion Matrix</i> Pada Pengujian <i>Unseen</i> Menggunakan Model 10	84
Tabel 4.62. Evaluasi Performa Pada Pengujian <i>Unseen</i> Menggunakan Model 10	84

Tabel 4.63. <i>Confusion Matrix</i> Pada Pengujian <i>Unseen</i> Menggunakan <i>Best Folder Model</i> Pada Pengujian 4.7.4	86
Tabel 4.64. Evaluasi Performa Pada Pengujian <i>Unseen</i> Menggunakan Model <i>Best Folder Model</i> pada Pengujian 4.7.4.....	86
Tabel 4.65. <i>Confusion Matrix</i> Pada Pengujian <i>Unseen</i> Menggunakan <i>Best Folder Model</i> Pada Pengujian 4.7.5	88
Tabel 4.66. Evaluasi Performa Pada Pengujian <i>Unseen</i> Menggunakan <i>Best Folder Model</i> pada Pengujian 4.7.5	88
Tabel 4.67. Perbandingan Keseluruhan Hasil DNN Pada <i>Train Test Split</i>	89
Tabel 4.68. Perbandingan Keseluruhan Hasil Pengujian <i>Unseen</i>	90

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 tidak berfungsi dengan baik, sehingga menyebabkan jantung berdetak tidak teratur, lebih lambat atau lebih cepat dari biasanya atau bahkan berbentuk gelombang.

Diagnosis aritmia jantung di dunia medis saat ini masih menggunakan teknologi *non-invasive*, yaitu elektrokardiogram. Elektrokardiogram (EKG) merupakan serangkaian pengujian untuk pemeriksaan kondisi jantung pasien 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 dari sekumpulan detak jantung, yaitu detak (*beat*) dan ritme jantung [4]. Diagnosis aritmia jantung harus menghasilkan interpretasi EKG yang akurat agar tidak menyebabkan salah tafsir detak jantung.

Diagnosis aritmia jantung secara manual sayangnya sering menyebabkan suatu masalah bagi kardiologis dalam merepresentasikan sinyal EKG. Durasi perekaman yang lama, kecilnya amplitude yang sulit dibedakan dengan mata serta memungkinkan terjadinya kesalahan (*human error*) dalam analisa perekaman EKG yang sangat lama [5].

Diagnosis aritmia jantung 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 [6] mengimplementasikan metode *Wavelet Transform* dan *Principal Component Analysis* (PCA) untuk mereduksi fitur kemudian diklasifikasi oleh *Support Vektor Machine* (SVM) untuk mengklasifikasikan beat pada sinyal EKG dan menghasilkan Akurasi 99.7%, *Sensitivitas* 99.09%, dan *Spesifisitas* 98.82% dengan enam jenis tipe beats pada aritmia jantung yang diklasifikasikan, yaitu *Atrial Premature Beat* (A), *Left Bundle Branch Block* (L), *Normal Beat* (N), *Paced Beat* (/), *Right Bundle Branch Block Beat* (R), dan *Premature Ventricular Contraction* (V).

Saat ini telah berkembang metode pembelajaran terawasi (*supervised Learning*) dengan *Deep Learning*, dimana fitur dipelajari secara otomatis, tanpa perlu mengekstraksi fitur campur tangan manusia [7]. *deep learning* dapat belajar dengan tingkat abstraksi yang lebih tinggi dari metode pembelajaran mesin sebelumnya. namun masih sedikit yang melakukan penelitian mengenai klasifikasi beat EKG kemudian mengklasifikasikan beat EKG menggunakan *Deep learning*. Rahhal, et al [8] mengimplementasikan *deep learning* dengan menggunakan *Autoencoder* untuk mereduksi dimensi fitur EKG kemudian mengklasifikasi beat EKG menggunakan *Deep Neural Network* dengan meraih performa yang lebih baik menggunakan 4 kelas beat (N,S,V dan F) yang diklasifikasikan. V.Bhayyu [9] mengimplemetasikan *deep learning* dengan menggunakan *Autoencoder* dan *Deep Neural Network* untuk mengklasifikasi beat EKG meraih performa yang lebih baik juga menggunakan 10 kelas beat (A,L,N,P,R,V,f,F,! dan j) 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* dengan mengklasifikasi 15 kelas.

1.2. Tujuan

Adapun tujuan dilakukan penelitian ini adalah :

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

1.3 Perumusan Masalah

Perumusan masalah yang ada pada tugas akhir ini adalah :

1. Penelitian ini menggunakan data dari *MIT-BIH Arrhythmia Database*.
2. Pengklasifikasian beat EKG dilakukan sebanyak 15 kelas, yaitu : *Normal Beat (N)*, *Atrial Premature Beat (A)*, *Premature Ventricular Contraction (V)*, *Right Bundle Branch Block (R)*, *Left Bundle Branch Block (L)*, *Aberrated Atrial Premature Beat (a)*, *Ventricular Flutter Wave (!)*, *Fusion of Ventricular and Normal (F)*, *Fusion of Paced and Normal (f)*, *Nodal Escape (j)*, *Nodal (Junctional) Premature (J)*, *Paced Beat (P)*, *Ventricular escape Beat (E)*, *Non- conducted P-wave (x)*, *Atrial escape Beat (e)*.
3. Penelitian ini hanya sebatas simulasi program dengan menggunakan bahasa pemrograman Python untuk membuat model *Deep Learning* untuk pengklasifikasian 15 kelas beat EKG dengan *Autoencoder* dan *Deep Neural Network*.

1.4 Sistematika Penulisan

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

BAB I PENDAHULUAN

Pada bab pertama ini berisi tentang 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 gelombang EKG, literature EKG, beat EKG, Deep Neural Network, dan Autoencoder.

BAB III METODOLOGI PENELITIAN

Pada bab ketiga ini menjelaskan tahap- tahap bagaimana penelitian ini berjalan dari persiapan data, pra-pemrosesan, pembagian data pelatihan dan pengujian, klasifikasi dan 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] H. Federation, “Global Atlas on cardiovascular disease prevention and control.”
- [2] A. Manuscript and C. Fibrosis, “Cardiac Fibrosis and Arrhythmogenesis: The Road to Repair is Paved with Perils,” pp. 83–91, 2015.
- [3] “J. R. Hampton, The ECG Made Easy, 8th ed. Elsevier Ltd, 2013.”
- [4] G. Tse, “Mechanisms of cardiac arrhythmias,” vol. 32, pp. 75–81, 2016.
- [5] N. A. M. E. Iii, “Errors in the computerized electrocardiogram interpretation of cardiac rhythm,” pp. 14–16.
- [6] Q. Qin, J. Li, L. Zhang, Y. Yue, and C. Liu, “Combining Low-dimensional Wavelet Features and Support Vector Machine for Arrhythmia Beat Classification,” *Sci. Rep.*, no. July, pp. 1–12, 2017.
- [7] T. Wiatowski and B. Helmut, “A Mathematical Theory of Deep Convolutional Neural Networks for Feature Extraction,” pp. 1–22.
- [8] M. Kim, H. Ko, and S. B. Pan, “A Study on User Recognition Using 2D ECG Image Based on Ensemble Networks for Intelligent Vehicles,” vol. 2019, 2019.
- [9] J. S. Komputer, F. I. Komputer, and U. Sriwijaya, “KLASIFIKASI BEAT EKG SECARA DEEP LEARNING MENGGUNAKAN AUTOENCODER DAN DEEP NEURAL NETWORK,” 2019.
- [10] W. Jatmiko, P. Mursanto, A. Bowolaksono, and B. Wiweko, “Teknik Biomedis : Teori dan Aplikasi,” no. January, 2012.
- [11] G. De Lannoy, B. Frenay, M. Verleysen, and J. Delbeke, “Supervised ECG Delineation Using the Wavelet Transform and Hidden Markov Models,” pp. 22–25, 2009.

- [12] A. F. Khalaf, M. I. Owis, and I. A. Yassine, "Expert Systems with Applications A novel technique for cardiac arrhythmia classification using spectral correlation and support vector machines," *Expert Syst. Appl.*, no. July, 2015.
- [13] Y. Xiao, "Cardiac arrhythmia and heart failure : From bench to bedside," pp. 131–132, 2011.
- [14] S. Nurmaini, A. Darmawahyuni, A. Noviar, and S. Mukti, "Deep Learning-Based Stacked Denoising and Autoencoder for ECG Heartbeat Classification," no. i, pp. 1–17, 2020.
- [15] B. Mohammadzadeh and S. Kamaledin, "Support vector machine-based arrhythmia classification using reduced features of heart rate variability signal," 2008.
- [16] M. G. Tsipouras, D. I. Fotiadis, and D. Sideris, "An arrhythmia classification system based on the RR-interval signal," pp. 237–250, 2005.
- [17] A. L. Goldberger *et al.*, "The online version of this article, along with updated information and services, is located on the World Wide Web at:," 2000.
- [18] S. Nurmaini, R. U. Partan, W. Caesarendra, and T. Dewi, "applied sciences An Automated ECG Beat Classification System Using Deep Neural Networks with an Unsupervised Feature Extraction Technique."
- [19] J. S. Komputer, F. I. Komputer, and U. Sriwijaya, "Segmentasi fitur sinyal ekg berdasarkan discrete wavelet transform dan windowed analysis untuk perhitungan qt correction dengan bazeet's formula," 2019.
- [20] M. N. A. E. A. El-dahshan and A. H. Yahia, "Denoising of Heart Sound Signals Using Discrete Wavelet Transform," *Circuits, Syst. Signal Process.*, 2017.

- [21] K. Palanisamy and S. Yaacob, "ECG Signal Denoising Using Wavelet Thresholding Techniques in Human Stress Assessment ECG Signal Denoising Using Wavelet Thresholding Techniques in Human Stress Assessment," no. November 2014, 2012.
- [22] H. Lin, S. Liang, Y. Ho, Y. Lin, and H. Ma, "Discrete-wavelet-transform-based noise removal and feature extraction for ECG signals," vol. 35, pp. 351–361, 2014.
- [23] S. Prodi, T. Informatika, F. Informatika, and U. Telkom, "KLASIFIKASI SINYAL ECG MENGGUNAKAN DEEP LEARNING DENGAN STACKED DENOISING AUTOENCODERS ECG SIGNAL CLASSIFICATION USING DEEP LEARNING WITH STACKED DENOISING AUTOENCODERS," vol. 4, no. 3, pp. 4719–4724, 2017.
- [24] K. G. Kim, "I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, Deep learning, vol. 1, no. 2. MIT press Cambridge, 2016.," vol. 22, no. 4, pp. 351–354, 2016.
- [25] Y. Bengio, "No Unbiased Estimator of the Variance of K-Fold Cross-Validation," vol. 5, pp. 1089–1105, 2004.
- [26] S. Saud, B. Jamil, Y. Upadhyay, and K. Irshad, "Performance improvement of empirical models for estimation of global solar radiation in India : A k - fold cross-validation approach," *Sustain. Energy Technol. Assessments*, vol. 40, no. April, p. 100768, 2020.
- [27] G. Sannino and G. De Pietro, "A deep learning approach for ECG-based heartbeat classification for arrhythmia detection," *Futur. Gener. Comput. Syst.*, vol. 86, pp. 446–455, 2018.
- [28] Y. Bengio and O. Delalleau, "On the Expressive Power of Deep Architectures," pp. 18–19, 2011.