

**KLASIFIKASI ARITMIA PADA SINYAL FETAL ECG
BERBASIS *DEEP LEARNING***

SKRIPSI

Diajukan Untuk Melengkapi Salah Satu Syarat

Memperoleh Gelar Sarjana Komputer



OLEH :

EZRA RISDA VIANTI

09011182025008

JURUSAN SISTEM KOMPUTER

FAKULTAS ILMU KOMPUTER

UNIVERSITAS SRIWIJAYA

2024

HALAMAN PENGESAHAN

KLASIFIKASI ARITMIA PADA SINYAL

FETAL ECG BERBASIS DEEP LEARNING

SKRIPSI

Program Studi Sistem Komputer

Jenjang S1

Oleh

Euna Rida Vianiti

09011182025003

Indralaya, *Y* Agustus 2024

Mengetahui,

Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.

NIP. 19661203200604100

Pembimbing Tugas Akhir

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

NIP. 196908021994012001

HALAMAN PERSETUJUAN

Telah diuji dan lulus pada :

Hari : Senin

Tanggal : 15 Juli 2024

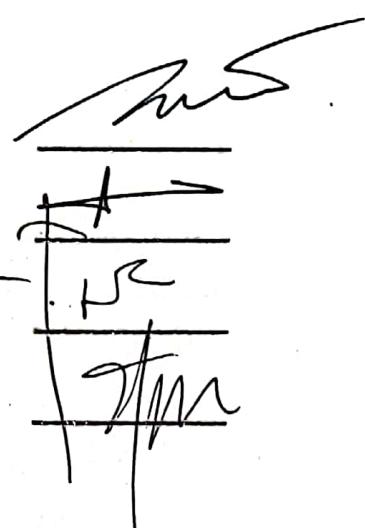
Tim Penguji :

1. Ketua : Dr. Rossi Passarella, M.Eng.

2. Sekretaris : Annisa Darmawahyuni, M.Kom.

3. Penguji : Dr. Firdaus, M.Kom.

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



Mengetahui, 16/8/24

Ketua Jurusan Sistem Komputer



Dr. Ir. Sukemi, M.T.

NIP. 19661203200604100

HALAMAN PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Ezra Risda Vianti

NIM : 09011182025008

Judul : Klasifikasi Aritmia pada Sinyal Fetal ECG berbasis *Deep Learning*

Hasil Pengecekan Software Turnitin : 3%

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 siapa pun.



Palembang, Juli 2024



Ezra Risda Vianti

NIM. 09011182025008

KATA PENGANTAR

Puji syukur kehadiran Tuhan Yang Maha Esa atas berkat, rahmat, dan penyertaan-Nya penulis telah diberikan kesehatan, kekuatan, serta kesanggupan sehingga penulis mampu menyelesaikan Tugas Akhir ini yang berjudul “Klasifikasi Aritmia pada Sinyal Fetal ECG berbasis *Deep Learning*”.

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

1. Orang tua penulis, Papa dan Mama, yang selalu memberikan motivasi, doa, serta dukungan atas jalan hidup yang dipilih oleh penulis dan menguatkan dalam menyelesaikan Tugas Akhir.
2. Bapak Prof. Dr. Erwin, S.Si., M.Si. selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
3. Bapak Dr. Ir. 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 penulis yang telah berkenan meluangkan waktu dalam membimbing penulis dalam penyusunan Proposal Tugas Akhir.
5. Bapak Dr. Ahmad Zarkasi, M.T., selaku Dosen Pembimbing Akademik penulis pada Program Studi Sistem Komputer.
6. Ibu Annisa Darmawahyuni M.Kom. selaku mentor penulis dalam menyelesaikan Proposal Tugas Akhir.
7. Bapak Prof. Dr. Ir. Bambang Tutuko, M.T., Bapak Dr. Firdaus, M.Kom., Bapak Muhammad Naufal Rachmatullah M.Kom., Ibu Dr. Ade Iriani Sapitri, M.Kom., Ibu Akhiar Wista Arum, M.Kom. dan Ibu Anggun Islami M.Kom. selaku Dosen yang terlibat dalam *Intelligent System Research Group*.
8. Semua mahasiswa/i, rekan sebaya penulis yang terlibat pada *Intelligent System Research Group* dan Sistem Komputer Angkatan 2020.

9. Teman dan sahabat penulis yang menjadi penguat penulis saat mengerjakan Tugas Akhir, terutama Zakhwa, Acha, dan Hanifa.
10. Infrastruktur laboratorium *Intelligent System Research Group* atas fasilitas yang telah disediakan sebagai penunjang Tugas Akhir.

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

Palembang, Juli 2024



Ezra Risda Vianti

NIM. 09011182025008

**KLASIFIKASI ARITMIA PADA SINYAL FETAL ECG
BERBASIS DEEP LEARNING**
EZRA RISDA VIANTI (09011182025008)

Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

Email : ezrarara.elg@gmail.com

ABSTRAK

Fetal Elektrokardiogram (EKG) merupakan salah satu jenis sinyal yang mencerminkan aktivitas elektrofisiologi dari jantung janin. *Metode non-invasive abdominal electrode* merupakan salah satu metode yang digunakan untuk meraih hasil dari sinyal *fetal* EKG. Klasifikasi dilakukan antara kategori normal dan *arrhythmia*, dengan dua pendekatan utama, yakni *autoencoder-Deep Neural Network* (DNN) dan *Convolutional Neural Network* (CNN). *Autoencoder* digunakan untuk ekstraksi fitur sebelum dilakukan klasifikasi dengan DNN. Evaluasi menunjukkan bahwa DNN dengan *autoencoder* menghasilkan akurasi terbaik sebesar 76%, presisi 83%, *recall* 83%, dan skor F1 79%. Sedangkan CNN menghasilkan performa lebih tinggi dengan akurasi 97%, presisi 100%, *recall* 99%, dan skor F1 97%. Meskipun CNN menunjukkan hasil metrik yang lebih baik, grafik *training loss* dan akurasi lebih optimal pada prosedur *autoencoder*-DNN. Dengan demikian, penelitian ini menunjukkan bahwa metode CNN lebih unggul dalam klasifikasi sinyal Fetal EKG, namun *autoencoder*-DNN juga memiliki potensi dengan optimasi yang lebih baik. Prosedur yang digunakan dalam penelitian kali ini dilangsungkan sebagai pemenuhan metode *deep learning* pada kecerdasan buatan terhadap *Non-Invasive Fetal ECG Arrhythmia Database* (NIFEADB).

Kata Kunci: Fetal EKG, *autoencoder*, DNN, CNN, NIFEADB, *deep learning*

ARRHYTHMIA CLASSIFICATION ON FETAL ECG USING DEEP LEARNING

EZRA RISDA VIANTI (09011182025008)

Computer System Department, Computer Science Faculty, Sriwijaya University

Email : ezrarara.elg@gmail.com

ABSTRACT

Fetal Electrocardiogram (ECG) is a type of signal that reflects the electrophysiological activity of the fetal heart. The non-invasive abdominal electrode method is employed to obtain fetal EKG signals. Classification was conducted between normal and arrhythmia categories using two main approaches, which are autoencoder-Deep Neural Network (DNN) and Convolutional Neural Network (CNN). The autoencoder was used for feature extraction before classification with DNN. Evaluation results indicated that the DNN with autoencoder achieved a best accuracy of 76%, precision of 83%, recall of 83%, and F1 score of 79%. In contrast, the CNN approach demonstrated higher performance with an accuracy of 97%, precision of 100%, recall of 99%, and F1 score of 97%. Although the CNN approach yielded better metric results, the training loss and accuracy graphs were more optimal in the autoencoder-DNN procedure. This study indicates that the CNN method is superior for classifying fetal ECG signals, yet the autoencoder-DNN approach also shows potential with better optimization. The procedures used in this study were conducted to fulfill deep learning methods in artificial intelligence for the Non-Invasive Fetal ECG Arrhythmia Database (NIFEA DB).

Keywords: *Fetal ECG, autoencoder, DNN, CNN, NIFEADB, deep learning*

DAFTAR ISI

HALAMAN JUDUL.....	i
HALAMAN PENGESAHAN.....	ii
HALAMAN PERSETUJUAN.....	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI	ix
DAFTAR GAMBAR	xi
DAFTAR TABEL	xii
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Tujuan.....	4
1.3. Perumusan Masalah.....	4
1.4. Batasan Masalah.....	4
1.5. Metodologi Penelitian	5
1.5.1. Tahap Pertama (Akuisisi Data)	5
1.5.2. Tahap Kedua (Pembuatan Sinyal Target)	5
1.5.3. Tahap Ketiga (Pra-pengolahan Sinyal)	5
1.5.4. Tahap Keempat (Klasifikasi, Pengujian, dan Validasi)	6
1.5.5. Tahap Kelima (Hasil dan Analisa)	6
1.5.6. Tahap Keenam (Penarikan Kesimpulan).....	6
1.6. Sistematika Penulisan.....	6
BAB II TINJAUAN PUSTAKA.....	
2.1. Penelitian Terdahulu	8
2.2. Elektrokardiogram.....	12
2.3. Fetal Cardiac Arrhythmia.....	13
2.4. Discrete Wavelet Transform	15
2.5. Autoencoder	16
2.6. Deep Neural Network.....	18
2.7. Convolutional Neural Network	20
2.8. Arrhythmia Rhythm Fetus.....	22
2.9. Normal Rhythm Fetus	23
2.10. Signal-to-Noise Ratio	25
2.11. Confusion Matrix	28
2.11.1. Akurasi	30
2.11.2. Recall Spesifitas	30
2.11.3. Presisi	31
2.11.4. F1 Score.....	31

BAB III METODOLOGI PENELITIAN.....	32
3.1. Kerangka Kerja	32
3.2. Pra-pengolahan Data	36
3.2.1. Denoising dan Normalisasi	37
3.2.2. Segmentasi	38
 BAB IV HASIL DAN PEMBAHASAN	40
4.1. Hasil Akuisisi Data.....	40
4.2. Hasil Pra-pengolahan Data.....	40
4.3. Hasil Segmentasi.....	43
4.4. Pemisahan Data Pelatihan, Pengujian, dan Validasi	44
4.5. Hasil Ekstraksi Fitur Autoencoder	45
4.6. Hasil Klasifikasi Arsitektur DNN dan CNN	48
4.7. Hasil Data Pengujian (Unseen) pada Klasifikasi DNN dan CNN	50
4.8. Grafik Training Loss dan Akurasi DNN	52
4.9. Grafik Training Loss dan Akurasi CNN	58
4.10. Hasil Confusion Matrix terhadap DNN	63
4.11. Hasil Confusion Matrix terhadap Data Pengujian (Unseen) DNN	68
4.12. Hasil Confusion Matrix terhadap CNN.....	75
4.13. Hasil Confusion Matrix terhadap Data Pengujian (Unseen) CNN	80
 BAB V KESIMPULAN	86
DAFTAR PUSTAKA	87

DAFTAR GAMBAR

Gambar 2.1 Arsitektur elektrokardiogram [11].....	12
Gambar 2.2 Komponen sinyal arrhythmia (ARR_01)	14
Gambar 2.3 Arsitektur autoencoder	17
Gambar 2.4 Arsitektur DNN	19
Gambar 2.5 Arsitektur CNN	21
Gambar 2.6 Arrhythmia Fetal EKG	23
Gambar 2.7 Normal Fetal EKG.....	24
Gambar 2.8 Confusion matrix	29
Gambar 3.1 Kerangka kerja autoencoder dan DNN	33
Gambar 3.2 Kerangka kerja CNN	35
Gambar 3.3 Blok diagram pra-pengolahan	37
Gambar 4.1 Hasil denoising pada sinyal normal.....	41
Gambar 4.2 Hasil denoising pada sinyal arrhythmia	41
Gambar 4.3 Hasil normalisasi pada sinyal normal.....	42
Gambar 4.4 Hasil normalisasi pada sinyal arrhythmia	42
Gambar 4.5 Hasil segmentasi sinyal arrhythmia.....	43
Gambar 4.6 Hasil segmentasi sinyal normal	44
Gambar 4.7 Training loss terhadap pelatihan autoencoder	46
Gambar 4.8 Rekonstruksi data dan error rekonstruksi dari autoencoder	47
Gambar 4.9 Grafik training loss dan akurasi DNN	53
Gambar 4.10 Grafik training Loss dan Akurasi CNN.....	58
Gambar 4.11 Confusion matrix terhadap DNN	64
Gambar 4.12 Hasil confusion matrix terhadap data unseen DNN	70
Gambar 4.13 Hasil confusion matrix terhadap CNN	76
Gambar 4.14 Hasil confusion matrix terhadap data unseen CNN	81

DAFTAR TABEL

Tabel 2.1 Rata-rata asil SNR.....	27
Tabel 4.1 Hasil autoencoder.....	45
Tabel 4.2 Hasil klasifikasi pada data validasi	49
Tabel 4.3 Hasil klasifikasi pada data uji (unseen).....	51

BAB I

PENDAHULUAN

1.1. Latar Belakang

Fetal EKG (elektrokardiogram) adalah sinyal yang mencerminkan aktivitas elektrofisiologi jantung janin dan dapat menunjukkan karakteristik *fetal hypoxia*. Analisis gelombang *fetal EKG* memungkinkan deteksi kelainan janin seperti gawat janin atau *intrauterine hypoxia*. Saat ini, ada dua metode untuk memperoleh *fetal EKG*: metode invasif dengan *scalp electrode* yang dapat mengukur sinyal murni selama kelahiran tetapi berisiko bagi ibu dan janin, serta metode non-invasif dengan *abdominal electrode* yang memungkinkan pemantauan jangka panjang selama kehamilan meskipun sinyalnya kompleks dan penuh *noise*. *Fetal EKG* dapat digunakan untuk menganalisis aktivitas jantung dan menentukan apakah irama detak jantung normal atau *abnormal* [1].

Penelitian kali ini, digunakan objek deteksi berupa dataset dari *Non-Invasive Fetal ECG Arrhythmia Database* (NIFEA DB), yang menyediakan serangkaian rekaman *fetal arrhythmia* sebanyak 12 rekaman dan sejumlah 14 rekaman ritme jantung *fetal* normal. Dataset ini dipilih karena memberikan variasi data yang cukup untuk menganalisis perbedaan antara sinyal aritmia dan sinyal normal pada jantung janin, sehingga dapat membantu dalam pengembangan metode deteksi yang lebih akurat dan andal [2].

Sinyal tersebut kemudian diolah dalam pra-pengolahan data dengan metode *discrete wavelet transform* (DWT). Pra-pengolahan sinyal melibatkan proses *denoising* (pengurangan derau), normalisasi, dan segmentasi pada masing-masing label sinyal. Langkah tersebut digunakan untuk menganalisis dan mempresetasikan sinyal dalam domain waktu-frekuensi. Cara kerja dari DWT adalah dengan membagi sinyal menjadi bagian-bagian dengan resolusi waktu yang berbeda (skala) dan mengidentifikasi komponen frekuensi pada setiap skala tersebut. Hal itu memungkinkan analisis sinyal pada berbagai tingkat detail dan memungkinkan deteksi

fitur pada berbagai tingkat resolusi. DWT juga menerapkan serangkaian filter rendah dan tinggi pada sinyal asli untuk menghasilkan aproksimasi (cA) dan detail (cD) pada tingkat dekomposisi tertentu. Detail yang dihasilkan pada setiap tingkat dekomposisi memberikan informasi tentang perubahan yang terjadi dalam sinyal, sementara aproksimasi memberikan informasi mengenai komponen frekuensi yang lebih halus. Setelah itu dekomposisi DWT sering direpresentasikan dalam bentuk struktur pohon, yang mana tingkat dekomposisi semakin dalam kearah cabang-cabang pohon. Hal ini memungkinkan representasi hierarkis dari sinyal, yaitu setiap tingkat pohon mewakili tingkat resolusi yang berbeda dari sinyal. DWT pula memiliki sifat lokal yang mana perubahan kecil dalam sinyal hanya akan memengaruhi sejumlah kecil koefisien transformasi. Yang mana membuat DWT menjadi alat yang kuat sebagai analisis lokal dalam sinyal, seperti deteksi tepi atau fitur lokal lainnya. DWT sering digunakan dalam aplikasi kompresi data karena kemampuannya untuk merepresentasikan sinyal dengan koefisien transformasi yang lebih sedikit daripada representasi sinyal asli. Ini membuatnya sangat berguna dalam kompresi citra dan sinyal, serta dalam aplikasi di mana pengurangan dimensi sinyal diperlukan [3].

Setelah melewati proses pengolahan dan pemotongan data pada masing-masing sinyal, maka sinyal akan diproses dengan ekstraksi fitur dengan menggunakan prosedur *autoencoder*, yang secara teori merupakan model *neural network* yang berupaya mengelola representasi terkompresi pada sebuah input, dengan demikian akan melakukan train untuk menyalin inputan menuju output. Metode *autoencoder* merupakan metode *unsupervised learning* yang secara teknis dilakukannya train menggunakan *supervised learning* yang disebut *self-supervised*. Biasanya dilakukan train sebagai bagian dari model yang lebih luas yang berupaya membuat ulang input pada *autoencoder*. *autoencoder* pula memiliki banyak jenis berdasarkan variasi penggunaannya, akan tetapi penggunaan yang lebih umum merupakan sebagai model *automatic feature extraction*. Dalam hal ini setelah model cocok, aspek rekonstruksi terhadap model dapat dibangun dan model hingga titik *bottleneck* dapat digunakan. Keluaran dari model pada *bottleneck* adalah *vector* dengan panjang tetap yang memberikan representasi terkompresi dari data masukan. Data masukan dari domain

kemudian dapat diberikan ke model dan keluaran dari model pada *bottleneck* dapat digunakan sebagai fitur vector dalam model *supervised learning* untuk visualisasi atau lebih umumnya untuk pengurangan dimensi [4].

Setelah melewati metode *autoencoder*, hasil terhadap ekstraksi fitur akan melakukan klasifikasi sesuai dengan metode *deep neural network* (DNN) yang mana telah menjadi alat yang ampuh untuk *machine learning* pada kecerdasan buatan. DNN merupakan bagian dari *artificial neural network* (ANN) dengan banyak lapisan (*layer*) antara lapisan input dan output. Model DNN pada awalnya terinspirasi oleh *neurobiology*. *Biological neuron* menerima banyak sinyal melalui sinapsis yang menghubungi dendritnya dan mengirimkan satu aliran potensial aksi melalui aksonnya pada tingkat tinggi. Kompleksitas beberapa input dikurangi dengan mengategorikan pola inputnya [5].

Selain menggunakan metode *autoencoder* dan DNN, penelitian dilakukan dengan menggunakan *convolutional neural network* (CNN). Cara kerja dari prosedur ini adalah dengan pembentukan model dengan arsitektur yang sesuai. Arsitektur ini melibatkan penentuan jumlah dan jenis lapisan konvolusi, penggabungan, dan sepenuhnya terhubung yang sesuai dengan masalah pemrosesan sinyal. Lalu akan dilakukan pelatihan model yang mana akan melibatkan data sinyal yang telah dikumpulkan dan mengalami proses pra-pengolahan sinyal.

Proses pelatihan model akan memproses data sinyal dan label yang sesuai dengan arsitektur model yang mana selanjutkan model akan diperbarui berdasarkan kesalahan antara prediksi model dan label. Apabila pelatihan model telah dilakukan, maka selanjutnya akan dilakukan validasi model menggunakan data yang tidak terlibat dalam pelatihan untuk mengevaluasi kinerja model secara objektif. Setelah model CNN dianggap memadai berdasarkan hasil validasi, kemudian akan diuji pada data sinyal baru yang belum pernah dilihat sebelumnya. Hal ini membantu untuk menilai kinerja model di dunia nyata yang memastikan bahwa itu dapat memberikan hasil yang mampu diandalkan dalam situasi praktis. Jika kinerja model tidak memenuhi harapan atau terdapat ruang untuk perbaikan, langkah-langkah penyesuaian dan

optimisasi dapat diambil dengan melibatkan perubahan dalam arsitektur model, penyesuaian parameter, atau teknik lainnya untuk meningkatkan kinerja model [6].

1.2. Tujuan

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

1. Menghilangkan derau pada sinyal *Fetal EKG* dengan metode *discrete wavelet transform*.
2. Membuat model klasifikasi terhadap kelainan aritmia berdasarkan *non-invasive fetal ECG arrhythmia database*.
3. Memperoleh hasil klasifikasi yang diproses melalui perantaraan objek sinyal yang diolah menggunakan bahasa pemrograman *python*.

1.3. Perumusan Masalah

Berdasarkan pemaparan latar belakang, dapat diuraikan perumusan masalah yang mencakup pengolahan *non-invasive fetal ECG arrhythmia database* untuk klasifikasi sinyal normal dan *arrhythmia*. Langkah pertama melibatkan penerapan *discrete wavelet transform* (DWT) untuk pra-pengolahan data, yang membantu mengekstraksi fitur penting dari sinyal. Selanjutnya, teknik deep learning diterapkan untuk mengenali pola dan anomali dalam sinyal, sehingga meningkatkan akurasi klasifikasi dan deteksi *arrhythmia* pada sinyal ECG non-invasif.

1.4. Batasan Masalah

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

1. Database yang digunakan merupakan *non-Invasive fetal ECG arrhythmia database*.
2. Penelitian menggunakan dua metode pada pendekatan kecerdasan buatan, yakni *deep learning*.

3. Klasifikasi diproses melalui perantaraan objek sinyal yang diolah menggunakan bahasa pemrograman *python*.

1.5. Metodologi Penelitian

Metodologi penelitian menjelaskan mengenai bagaimana prosedur sinyal dilakukan. Dalam penjelasan tersebut akan teruraikan bagaimana cara kerja dari setiap langkah pada pengolahan sinyal.

1.5.1. Tahap Pertama (Akuisisi Data)

Pada tahap pertama, penulis melakukan akuisisi data dengan tujuan untuk mendapatkan bentuk awal data sebelum diekstraksi dan memperoleh sinyal EKG dari *database* tersebut. Proses ini melibatkan pengumpulan data mentah dari berbagai sumber yang relevan. Setelah itu, data yang diperoleh akan disimpan dalam format yang sesuai untuk tahap ekstraksi selanjutnya.

1.5.2. Tahap Kedua (Pembuatan Sinyal Target)

Pada tahap kedua, penulis melakukan pemisahan dan pelabelan terhadap sinyal EKG. Hal ini dikarenakan di dalam *database* sinyal terdapat empat sinyal *abdominal* (sinyal perut) yang terekam dalam hasil rekaman sinyal. Pelabelan dilakukan dengan kategori dua sinyal, yakni sinyal normal dan sinyal aritmia (*abnormal*).

1.5.3. Tahap Ketiga (Pra-pengolahan Sinyal)

Pada tahap ketiga, penulis melakukan pra-pengolahan sinyal sebelum sinyal diolah dalam prosedur klasifikasi. Pra-pengolahan sinyal melibatkan proses pengurangan derau, normalisasi, dan juga segmentasi. Pengurangan derau dilakukan untuk memastikan sinyal yang dianalisis bebas dari gangguan yang dapat mempengaruhi akurasi klasifikasi. Sementara normalisasi memengaruhi sinyal agar menjadi lebih stabil hingga pengolahan data terjadi lebih baik. Setelah mengalami pengurangan derau dan normalisasi, maka sinyal bisa dilakukan segmentasi atau pemotongan sinyal.

1.5.4. Tahap Keempat (Klasifikasi, Pengujian, dan Validasi)

Pada tahap keempat, penulis melakukan pengujian dari model yang dibentuk dan melampirkan hasil dari peforma serta kinerja dari model yang dibentuk. Penulis melakukan pengujian hingga sesuai dengan ekspektasi hasil kinerja.

1.5.5. Tahap Kelima (Hasil dan Analisa)

Pada tahap kelima, penulis menguraikan analisa terhadap hasil pengujian model yang telah dibuat, sehingga hasil analisa mampu dipergunakan sebagai referensi dalam penelitian selanjutnya.

1.5.6. Tahap Keenam (Penarikan Kesimpulan)

Pada tahap keenam, penulis menarik kesimpulan berdasarkan penelitian yang telah dilakukan. Diharapkan hasil kesimpulan mampu dijadikan referensi ketika melakukan penelitian selanjutnya.

1.6. Sistematika Penulisan

Sistematika penulisan menjelaskan mengenai sinopsis setiap bab yang akan diuraikan pada peneltian kali ini, mulai dari BAB I hingga BAB V. Pembaca dapat menemukan bagian inti dari hasil penulisan ini sesuai dengan keperluan pembaca. Yang mana yang telah dirangkum sebagai berikut.

BAB I PENDAHULUAN

Bab I menjelaskan mengenai hal-hal dasar dalam penulisan Tugas Akhir ini. Hal-hal dasar tersebut ialah latar belakang, tujuan, manfaat, batasan masalah, metode penelitian, dan juga sistematika penulisan.

BAB II TINJAUAN PUSTAKA

Bab II menjelaskan mengenai landasan dasar teori, cara serta konsep kerja yang nantinya akan menjabarkan aturan dasar dalam memecahkan masalah kasus penelitian dan memperkuat validasi dan penelitian yang dibuat.

BAB III METODOLOGI PENELITIAN

Bab III menjelaskan secara rinci mengenai penguraian metodologi yang digunakan dalam penelitian ini. Bab ini, akan dibahas secara mendalam berbagai teknik dan metode yang diaplikasikan serta alur proses yang diikuti selama penelitian berlangsung. Pembahasan mencakup langkah-langkah sistematis yang diambil untuk mengumpulkan, mengolah, dan menganalisis data, termasuk justifikasi pemilihan teknik tertentu serta bagaimana metode tersebut diterapkan dalam konteks penelitian.

BAB IV HASIL DAN PEMBAHASAN

Bab IV menjelaskan mengenai tampilan hasil penelitian berdasarkan pengujian yang telah dilakukan, memberikan analisa terhadap hasil pengujian, serta uraian pembahasan dari masing-masing keluaran hasil dan analisanya.

BAB V KESIMPULAN DAN SARAN

BAB V menjelaskan mengenai kesimpulan berdasarkan hasil penelitian yang dilakukan pada Tugas Akhir dan berperan sebagai referensi untuk penelitian seterusnya yang memiliki keterkaitan topik / tema.

DAFTAR PUSTAKA

- [1] A. Matonia *et al.*, “Fetal Electrocardiograms, Direct and Abdominal with Reference Heartbeat Annotations,” *Sci. Data*, vol. 7, no. 1, Dec. 2020, doi: 10.1038/s41597-020-0538-z.
- [2] E. Sulas, M. Urru, R. Tumbarello, L. Raffo, R. Sameni, and D. Pani, “A Non-Invasive Multimodal Foetal ECG–Doppler Dataset for Antenatal Cardiology research,” *Sci. Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1038/s41597-021-00811-3.
- [3] A. N. Skodras and A. N. Skodras, “Discrete Wavelet Transform : An Introduction Discrete Wavelet Transform : An Introduction,” p. 26, 2003.
- [4] Q. Meng, D. Catchpoole, D. Skillicorn, and P. J. Kennedy, “Relational Autoencoder for Feature Extraction,” Feb. 2018, doi: 10.1109/IJCNN.2017.7965877.
- [5] M. G. Galety, F. H. Al Mukthar, R. J. Maaroof, and F. Rofoo, “Deep Neural Network Concepts for Classification using Convolutional Neural Network: A Systematic Review and Evaluation,” 2021. [Online]. Available: www.techniumscience.com
- [6] M. Krichen, “Convolutional Neural Networks: A Survey,” *Computers*, vol. 12, no. 8, pp. 1–41, 2023, doi: 10.3390/computers12080151.
- [7] R. K. Rai, A. Singh, R. Srivastva, and G. Kumar, “Fetal ECG Arrhythmia Detection Based on DensNet Transfer Learning,” *Front. Biomed. Technol.*, vol. 10, no. 4, pp. 417–426, 2023, doi: 10.18502/fbt.v10i4.13723.
- [8] M. Wu, Y. Lu, W. Yang, and S. Y. Wong, “A Study on Arrhythmia via ECG Signal Classification Using the Convolutional Neural Network,” *Front. Comput. Neurosci.*, vol. 14, no. January, pp. 1–10, 2021, doi: 10.3389/fncom.2020.564015.
- [9] K. Sharma and S. Masood, “Deep Learning-Based Non-invasive Fetal Cardiac Arrhythmia Detection,” in *Lecture Notes in Electrical Engineering*, Springer Science and Business Media Deutschland GmbH, 2021, pp. 511–523. doi:

- 10.1007/978-981-16-3067-5_38.
- [10] X. Shi, K. Yamamoto, T. Ohtsuki, Y. Matsui, and K. Owada, “Unsupervised Learning-Based Non-Invasive Fetal ECG Muti-Level Signal Quality Assessment,” *Bioengineering*, vol. 10, no. 1, p. 66, Jan. 2023, doi: 10.3390/bioengineering10010066.
 - [11] S. Aziz, S. Ahmed, and M. S. Alouini, “OPEN ECG - based Machine - Learning Algorithms for Heartbeat Classification,” *Sci. Rep.*, pp. 1–14, 2021, doi: 10.1038/s41598-021-97118-5.
 - [12] M. A. Serhani, H. T. El Kassabi, H. Ismail, and A. N. Navaz, “ECG Monitoring Systems: Review, Architecture, Processes, and Key Challenges,” *Sensors (Switzerland)*, vol. 20, no. 6, 2020, doi: 10.3390/s20061796.
 - [13] E. Fotiadou and R. Vullings, “Multi-Channel Fetal ECG Denoising With Deep Convolutional Neural Networks,” *Front. Pediatr.*, vol. 8, Aug. 2020, doi: 10.3389/fped.2020.00508.
 - [14] A. Rashkovska and V. Avbelj, “Abdominal Fetal ECG Measured with Differential ECG Sensor,” *2017 40th Int. Conv. Inf. Commun. Technol. Electron. Microelectron. MIPRO 2017 - Proc.*, no. Bluetooth 4, pp. 289–291, 2017, doi: 10.23919/MIPRO.2017.7973436.
 - [15] R. Hayati and R. Kurnia, “Simulasi Unjuk Kerja Discrete Wavelet Transform (DWT) dan Discrete Cosine Transform (DCT) untuk Pengolahan Sinyal Radar di Daerah yang Ber-Noise Tinggi,” *J. Nas. Tek. Elektro*, vol. 3, no. 1, p. 32, 2014, doi: 10.25077/jnte.v3n1.53.2014.
 - [16] M. A. Wafa, S. Mandala, and M. Pramudyo, “Performance Analysis of PPG Signal Denoising Method Using DWT and EMD for Detection of PVC and AF Arrhythmias,” *Indones. J. Comput.*, vol. 7, no. 2, pp. 35–44, 2022, doi: 10.34818/indojc.2022.7.2.648.
 - [17] R. D. Siregar, “Klasifikasi Kelainan Irama Jantung Aritmia dengan Kombinasi Metode Denoising Autoencoder-Autoencoder dan,” 2021.
 - [18] A. Saxena, “An Introduction to CNN,” *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 10, no. 12, pp. 943–947, 2022, doi: 10.22214/ijraset.2022.47789.

- [19] A. Patil and M. Rane, “Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition,” *Smart Innov. Syst. Technol.*, vol. 195, pp. 21–30, 2021, doi: 10.1007/978-981-15-7078-0_3.
- [20] H. S. Ibrahim and U. N. Wisesty, “Analisis Deep Learning untuk Mengenali QRS Kompleks Pada Sinyal ECG dengan Metode CNN,” *e-Proceeding Eng.*, vol. 5, no. 2, pp. 3718–3725, 2018.
- [21] A. Anton, N. F. Nissa, A. Janiati, N. Cahya, and P. Astuti, “Application of Deep Learning Using Convolutional Neural Network (CNN) Method For Women’s Skin Classification,” *Sci. J. Informatics*, vol. 8, no. 1, pp. 144–153, 2021, doi: 10.15294/sji.v8i1.26888.
- [22] J. Song and Y. Chen, “A Study on the Application and the Advancement of Deep Neural Network Algorithm,” *J. Phys. Conf. Ser.*, vol. 2146, no. 1, 2022, doi: 10.1088/1742-6596/2146/1/012001.
- [23] S. Nurmaini, R. Umi P, M. Naufal, and A. Gani, “Cardiac Arrhythmias Classification Using Deep Neural Networks and Principle Component Analysis Algorithm,” 2018.
- [24] S. Nurmaini, A. Darmawahyuni, A. N. S. Mukti, M. N. Rachmatullah, F. Firdaus, and B. Tutuko, “Deep learning-based stacked denoising and autoencoder for ECG heartbeat classification,” *Electron.*, vol. 9, no. 1, Jan. 2020, doi: 10.3390/electronics9010135.
- [25] D. Mochamad Reza, Satria Mandala, S. M. Zaki, and E. S. L. Ming, “Deep Learning Autoencoder Study on ECG Signals,” *J. Nas. Tek. Elektro*, vol. 3, pp. 82–88, 2023, doi: 10.25077/jnte.v12n3.1117.2023.
- [26] N. Bravo-Valenzuela, L. Rocha, L. Machado Nardozza, and E. Júnior, “Fetal cardiac arrhythmias: Current evidence,” *Ann. Pediatr. Cardiol.*, vol. 11, no. 2, pp. 148–163, 2018, doi: 10.4103/apc.APC_134_17.
- [27] Y. Zhang *et al.*, “Wearable Fetal ECG Monitoring System from Abdominal Electrocardiography Recording,” *Biosensors*, vol. 12, no. 7, 2022, doi: 10.3390/bios12070475.
- [28] P. N. Malleswari* and B. Renuka, “EMD-DWT Based ECG Denoising

- Technique using Soft Thresholding,” *Int. J. Recent Technol. Eng.*, vol. 8, no. 6, pp. 4891–4894, 2020, doi: 10.35940/ijrte.f8885.038620.
- [29] S. Lohbare and S. Dixit, “Elimination of Noise from Ambulatory ECG Signal using DWT,” *Int. J. Eng. Trends Technol.*, vol. 70, no. 5, pp. 266–273, 2022, doi: 10.14445/22315381/IJETT-V70I5P229.
- [30] X. Xie, S. Peng, and X. Yang, “Deep Learning-Based Signal-To-Noise Ratio Estimation Using Constellation Diagrams,” *Mob. Inf. Syst.*, vol. 2020, 2020, doi: 10.1155/2020/8840340.
- [31] A. I. Fathyani and A. P. Rahardian, “Analisis Nilai Signal to Noise to Noise Ratio (SNR) akibat Variasi Nex pada Pemeriksaan MRI Thoracolumbal Sekuen Sagittall T2 FAT SAT pada Kasus Low Back Pain (LBP)”, vol. 5, pp. 1744–1752, 2024.
- [32] W. Zhang, M. Feng, M. Krunz, A. Hossein, and Y. Abyaneh, “Signal Detection and Classification in Shared Spectrum: A Deep Learning Approach,” 2021.
- [33] X. Li, X. Wang, Y. Qin, and J. Li, “SNR Classification Based Multi-Estimator IRM Speech Enhancement Algorithm,” *J. Phys. Conf. Ser.*, vol. 2173, no. 1, 2022, doi: 10.1088/1742-6596/2173/1/012086.
- [34] Y. N. Chen, K. C. Fan, Y. L. Chang, and T. Moriyama, “Special Issue Review: Artificial Intelligence and Machine Learning Applications in Remote Sensing,” *Remote Sens.*, vol. 15, no. 3, pp. 1–10, 2023, doi: 10.3390/rs15030569.
- [35] A. Darmawahyuni *et al.*, “Accurate Fetal QRS-Complex Classification from Abdominal Electrocardiogram Using Deep Learning,” *Int. J. Comput. Intell. Syst.*, vol. 16, no. 1, pp. 1–10, 2023, doi: 10.1007/s44196-023-00339-x.
- [36] A. A. Ahmed, W. Ali, T. A. A. Abdullah, and S. J. Malebary, “Classifying Cardiac Arrhythmia from ECG Signal Using 1D CNN Deep Learning Model,” *Mathematics*, vol. 11, no. 3, p. 562, 2023, doi: 10.3390/math11030562.
- [37] K. M. Ting, “Confusion Matrix,” *Encycl. Mach. Learn. Data Min.*, no. October, pp. 260–260, 2017, doi: 10.1007/978-1-4899-7687-1_50.