

DISERTASI

**KLASIFIKASI SINYAL ELEKTROKARDIOGRAM PADA
PENYAKIT JANTUNG BERDASARKAN ANALISIS FITUR
*HEART RATE VARIABILITY***



FEBRIYANTI PANJAITAN

03043681823003

PROGRAM STUDI ILMU TEKNIK

FAKULTAS TEKNIK

UNIVERSITAS SRIWIJAYA

2023

HALAMAN PENGESAHAN

**KLASIFIKASI SINYAL ELEKTROKARDIAGRAM PADA
PENYAKIT JANTUNG BERDASARKAN ANALISIS FITUR
*HEART RATE VARIABILITY***

LAPORAN AKHIR DISERTASI


Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Doktor

Oleh :

FEBRIYANTI PANJAITAN
NIM : 03043681823003

Promotor

Palembang, Januari 2024
Co- Promotor



Prof. Ir. Siti Nurmaini, M.T. Ph.D
NIP. 196908021994012001



Prof. Dr. dr. Radiyah Umami Partan, SpPD-KR, M.Kes.
NIP. 197207172008012007

**Mengetahui,
Dekan Fakultas Teknik**

Ketua Program Studi



Dr. Eng. Ir. H. Joni Arliansyah, M.T
NIP : 196706151995121002



Prof. Dr. Ir. Nukman, MT.
NIP : 195903211987031001


HALAMAN PERSETUJUAN

Karya tulis ilmiah berupa Laporan Disertasi ini dengan judul “Klasifikasi Sinyal Elektrokardiogram pada Penyakit Jantung Berdasarkan Analisis Fitur *Heart Rate Variability*”, telah dipertahankan di hadapan Tim Penguji Karya Tulis Ilmiah Fakultas Teknik Program Studi Doktor Ilmu Teknik Universitas Sriwijaya pada tanggal 14 Desember 2023.

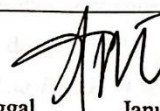
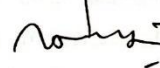
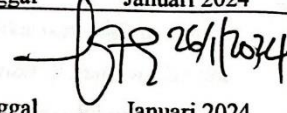
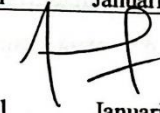
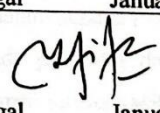
Palembang, Januari 2024

Tim Penguji Karya Tulis ilmiah berupa Laporan Disertasi :

Ketua:

Dr. Ir. Bhakti Yudho Suprpto, S.T., M.T., IPM NIP. 197502112003121002	() Tanggal Januari 2024
--	---

Anggota :


Prof. Ir. Siti Nurmaini, M.T. Ph.D NIP. 196908021994012001	() Tanggal Januari 2024
Prof. Dr. dr. Radiyati Umi Partan, SpPD-KR, M.Kes NIP. 197207172008012007	() Tanggal Januari 2024
Prof. Dr. Ir. Bambang Tutuko, M.T. NIP. 196001121989031002	() Tanggal Januari 2024
Dr. M. Fachrurrozi, S.Si., M.T. NIP. 198005222008121002	() Tanggal Januari 2024
Dr. Nyayu Latifah Husni. S.T., M.T. NIP. 19760503 200112 2 002	() Tanggal Januari 2024

Mengetahui,
 Dekan Fakultas Teknik



Dr. Eng. Ir. H. Joni Arliansyah, M.T.
 NIP: 196706151995121002

Ketua Program Studi



Prof. Dr. Ir. Nukman, MT.
 NIP: 195903211987031001

SURAT PERNYATAAN

Saya yang bertandatangan di bawah ini:

Nama : Febriyanti Panjaitan
NIM : 03043681823003
Program Studi : Ilmu Teknik Program Doktor
Fakultas : Teknik
Perguruan Tinggi : Universitas Sriwijaya
Alamat : Palembang

Dengan ini menyatakan bahwa Disertasi saya dengan judul “Klasifikasi Sinyal Elektrodiagram pada Penyakit Jantung Berdasarkan Analisis Fitur *Heart Rate Variability*” bebas dari plagiat.

Demikian pernyataan ini dibuat dengan sesungguhnya dan dengan sebenar-benarnya.

Palembang, 4 Desember 2023
Yang menyatakan,



Febriyanti Panjaitan
NIM. 03043681823005

KATA PENGANTAR

Terima kasih kepada Tuhan Yang Maha Esa atas berkat dan anugerah-Nya yang telah memungkinkan saya menyelesaikan disertasi ini. Disertasi ini menandai perjalanan saya dalam menyelesaikan program Doktorat dan merupakan salah satu tugas terpenting pada semester akhir saya. Kesuksesan dalam menyelesaikan disertasi ini menandakan langkah penting dalam perjalanan studi doktorat saya.

Gagasan dalam disertasi ini telah melalui banyak review, observasi, dan analisis yang cermat. Dengan bimbingan serta arahan dari promotor saya, Prof. Ir. Siti Nurmaini, M.T, PhD, dan ko-promotor saya, Prof. Dr. dr. Radiyati Ummi Partan, SpPD-KR, M.Kes.. Saya telah berpartisipasi dalam dua konferensi, yaitu ICECOS2019 di Batam pada 02-03 Oktober 2019 dengan judul artikel "*Identification of Classification Method for Sudden Cardiac Death: A Review*", serta ICIMSI 2023 di Jakarta pada 7-8 November 2023 dengan judul "*Hyperparameter Optimization in Machine Learning for Heart Disease Classification based on Heart Rate Variability Feature Analysis*".

Selain itu, hasil penelitian ini juga telah dipublikasikan dalam jurnal MEDICINA-MDPI dengan judul artikel "*Accurate Prediction of Sudden Cardiac Death Based on Heart Rate Variability Analysis Using Convolutional Neural Network*". Jurnal ini tergolong *Journal Scopus Q2* dengan *impact factor 2.6* dan memiliki h-indeks 52, serta terdaftar di *Pubmed*.

Saya ingin menyampaikan rasa terima kasih yang mendalam kepada Prof. Dr. Ir. Nukman, M.T. selaku ketua program studi, serta kepada promotor dan ko-promotor saya atas bimbingan yang berkesinambungan. Ucapan terima kasih juga saya sampaikan atas dedikasi, motivasi, koreksi, dan saran yang sangat berharga dari mereka.

Terima kasih juga kepada Universitas Bina Darma atas izin dalam studi doktorat ini. Serta terima kasih kepada teman-teman kerja terdekat dan rekan-rekan seperjuangan di Program Doktor Ilmu Teknik Universitas Sriwijaya.

Akhirnya, saya ingin mengucapkan terima kasih kepada orang tua dan keluarga saya atas dukungan, dorongan, serta pengertian yang selalu mereka berikan.

Palembang, Desember 2023

Penulis

A handwritten signature in blue ink, consisting of a large, stylized initial 'F' followed by a cursive 'P' and a horizontal line.

Febriyanti Palaitan

RINGKASAN

Klasifikasi Sinyal Elektrokardiogram Pada Penyakit Jantung Menggunakan *Convolutional Neural Network* Berdasarkan Analisis Fitur *Heart Rate Variability*.

Karya ini merupakan Disertasi Febriyanti Panjaitan, M.Kom.

Program Studi Doktor Ilmu Teknik bidang kajian utama Teknik Informatika,
Fakultas Teknik Universitas Sriwijaya

Dibimbing oleh :

Prof. Ir. Siti Nurmaini, M.T., Ph.D.

Prof. Dr. dr. Radiyati Umami Partan, SpPD-KR, M.Kes.

xxii + 173, 54 gambar, 52 tabel, 4 lampiran

Penelitian ini bertujuan untuk mengevaluasi keoptimalan metode 1D CNN-Wavenet menggunakan dataset yang diperluas menjadi sebelas fitur HRV, melibatkan empat subjek penyakit jantung dengan durasi EKG 30 menit. Pada penelitian awal, penggunaan HRV untuk memprediksi SCD mencapai akurasi maksimum 99.42%. Penelitian ini kemudian melanjutkan penelitian pada tahapan awal dengan memperluas *dataset*, menambahkan fitur time domain dan fitur non-linear.

Selain itu, penelitian ini menguji keoptimalan model dengan menggunakan lima metode machine learning (ML) sebagai perbandingan untuk mengukur keoptimalan model Deep Learning (DL) yang telah dikembangkan. Pengujian dilakukan menggunakan tiga jenis data: data uji, data latih, dan data yang belum pernah dilihat sebelumnya (unseen).

Hasil penelitian menunjukkan bahwa penggunaan sebelas fitur HRV dengan metode SVM memberikan hasil yang lebih unggul dibandingkan metode lainnya. Pada data latih dan data uji, metode SVM dan DT mencapai nilai akurasi 100%, sementara CNN mencapai 99.13%. Ketiga model ini kemudian diuji kembali menggunakan data unseen, dan hasilnya menunjukkan bahwa SVM tetap

memberikan nilai akurasi, sensitivitas, spesifisitas, dan presisi sebesar 100%. Sedangkan metode DT mencapai akurasi sebesar 96.67%, sensitivitas 91.67%, spesifisitas 100%, dan presisi 93.33%. Metode CNN mencapai akurasi 98.73%, sensitivitas 97.22%, spesifisitas 98.47%, dan presisi 96.44%

Penggunaan metode SVM dengan sebelas fitur HRV menunjukkan kinerja yang sangat baik dalam memprediksi penyakit jantung, khususnya pada data yang belum pernah dilihat sebelumnya, dengan akurasi yang mencapai 100%. Metode DT juga memiliki kinerja yang baik, sedangkan CNN memiliki performa yang sedikit lebih rendah namun masih sangat baik untuk klasifikasi penyakit jantung.

Metodologi ini memerlukan pengujian lebih lanjut pada fitur HRV, termasuk fitur frekuensi waktu, untuk mengembangkan teknik diagnostik yang lebih konkret.

Kata kunci : *Convolutional Neural Network, Machine Learning, Heart Rate Variability, Wavenet, Cardiac Disease, Classification*

SUMMARY

Classification of Electrocardiogram Signals in Heart Disease Using Convolutional Neural Network Based on Heart Rate Variability Feature Analysis.

This work is a Dissertation by Febriyanti Panjaitan, M.Kom.

Study Program of Engineering Sciences with a major focus on Computer Engineering, Faculty of Engineering at Universitas Sriwijaya.

Supervised by :

Prof. Ir. Siti Nurmaini, M.T., Ph.D.

Prof. Dr. dr. Radiyati Umami Partan, SpPD-KR, M.Kes.

xxii + 173, 54 figures, 52 tables, 4 appendices

The study aims to evaluate the optimization of the 1D CNN-Wavenet method using an expanded dataset involving eleven HRV features, encompassing four subjects with a 30-minute ECG duration and heart disease. In the initial research phase, HRV utilization for predicting SCD achieved a maximum accuracy of 99.42%. This study continued the initial research by expanding the dataset, incorporating time-domain features, and non-linear features.

The research findings indicated that using eleven HRV features with the SVM method produced superior results compared to other methods. In both training and test datasets, the SVM and DT methods achieved an accuracy of 100%, while CNN reached 99.13%. Subsequently, these three models were retested with unseen data, and the results demonstrated that SVM maintained accuracy, sensitivity, specificity, and precision at 100%. DT achieved an accuracy of 96.67%, sensitivity of 91.67%, specificity of 100%, and precision of 93.33%. CNN showed an accuracy of 98.73%, sensitivity of 97.22%, specificity of 98.47%, and precision of 96.44%.

The utilization of the SVM method with eleven HRV features showcased excellent performance in predicting heart diseases, particularly on previously unseen data,

attaining 100% accuracy. DT exhibited good performance, whereas CNN displayed slightly lower but still excellent performance in heart disease classification.

This methodology necessitates further testing on HRV features, including time-frequency features, to develop more concrete diagnostic techniques.

Keywords : Convolutional Neural Network, Machine Learning, Heart Rate Variability, Wavenet, Cardiac Disease, Classification

DAFTAR ISI

HALAMAN PENGESAHAN	ii
HALAMAN PERSETUJUAN.....	iii
KATA PENGANTAR	v
RINGKASAN	vi
SUMMARY	viii
DAFTAR ISI.....	x
DAFTAR GAMBAR	xiv
DAFTAR TABEL.....	xviii
DAFTAR ISTILAH	xx
DAFTAR LAMPIRAN.....	xxi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Perumusan Masalah.....	3
1.3 Tujuan Penelitian.....	4
1.4 Ruang Lingkup Penelitian	4
1.5 Sistematika Proposal	5
BAB 2 TINJAUAN PUSTAKA	6
2.1 Sinyal Elektrokardiogram.....	6
2.2 Sinyal Elektrokardiogram lima Kelompok Pembanding.....	7
2.2.1 Subjek <i>Sudden Cardiac Death</i>	7
2.2.2 Subjek <i>Coronary Artery Disease</i>	8
2.2.3 Subjek <i>Congestive Heart Failure</i>	8
2.2.4 Subjek <i>Ventricular Tachycardia</i>	9
2.2.5 Subjek Normal	10
2.3 <i>State of the art</i>	11
2.4 <i>Machine Learning</i>	13
2.4.1 <i>Support Vector Machine</i>	15
2.4.2 K-Nearest Neighbors.....	16
2.4.3 <i>Decision Tree</i>	16
2.4.4 <i>Random Forest</i>	17

2.4.5	<i>Multilayer Perceptron</i>	17
2.5	<i>Deep Learning</i>	19
2.5.1	<i>Convolutional Neural Network</i>	20
2.5.2	<i>Wavenet</i>	22
2.5.3	<i>CNN-Wavenet</i>	24
2.6	Evaluasi kinerja klasifikasi.....	26
BAB 3 METODOLOGI PENELITIAN.....		28
3.1	Kerangka Penelitian.....	28
3.1.1	<i>Dataset</i>	29
3.1.2	Pra-pemrosesan	31
3.1.2.1	Segmentasi	31
3.1.2.2	<i>Denoising</i>	42
3.1.2.3	Normalisasi	45
3.1.2.4	<i>R-Peaks</i>	46
3.1.2.5	RR Interval.....	49
3.1.3	Ekstraksi Fitur	50
3.1.3.1	Fitur <i>Mean of RR intervals</i>	50
3.1.3.2	Fitur <i>Standard Deviation of RR intervals</i>	52
3.1.3.3	Fitur NN50	52
3.1.3.4	Fitur <i>Root Mean Square of Differences of successive RR intervals</i>	53
3.1.3.5	Fitur <i>Percentage of NN50</i>	54
3.1.3.6	Fitur <i>Coefficient of Variation of RR Interval</i>	55
3.1.3.7	Fitur Minimal RR Interval	55
3.1.3.8	Fitur Maksimal Interval RR.....	56
3.1.3.9	Fitur <i>Standard Deviation</i> ₁	57
3.1.3.10	Fitur <i>Standard Deviation</i> ₂	57
3.1.3.11	Fitur SD ₁₂	58
3.1.4	Klasifikasi	59
3.1.4.1	Persiapan Data	60
3.1.4.1.1	<i>Label Data</i>	60

3.1.4.1.2	<i>EncodedLabel</i>	62
3.1.4.1.3	One Hot <i>Encoding</i>	64
3.1.4.1.4	Normalisasi Data	65
3.1.4.1.5	Data Latih Dan Data Uji.....	66
3.1.4.2	Model <i>Machine Learning</i>	67
3.1.4.2.1	<i>Support Vector Machine</i>	68
3.1.4.2.3	<i>K-Nearest Neighbors</i>	71
3.1.4.2.4	<i>Decision Tree</i>	72
6.1.4.1.2	<i>Multilayer Perceptron</i>	76
6.1.4.1.3	<i>Random Forest</i>	77
3.1.4.3	<i>Deep Learning</i>	78
3.1.4.3.1	Model CNN- <i>Wavenet</i>	78
3.1.4.4	Pengujian Unseen Data.....	84
BAB 4 HASIL DAN PEMBAHASAN		87
4.1	Pra-pemrosesan dari EKG ke fitur HRV	87
4.2	Data per-Segmen	88
4.3	Pengembangan Model pada Arsitektur <i>Machine Learning</i>	89
4.3.1	Metode <i>Support Vector Machin</i> dan <i>Decesion Tree</i>	90
4.3.2	Metode <i>K-Nearest Neighbors</i>	102
4.3.3	Metode <i>Multi-Layer Perceptron</i>	108
4.3.4	Metode <i>Random Forest</i>	114
4.4.	Pengembangan Model pada Arsitektur <i>Deep Learning</i>	123
4.4.1	Metode CNN- <i>Wavenet</i>	124
4.4.4.1	3 Hidden Layer	124
4.4.1.2	5 Hidden Layer	125
4.4.1.3	7 Hidden Layer	127
4.4.1.4	9 Hidden Layer	128
4.4.2	Hasil Akurasi dan loss dari model yang diusulkan	135
4.5	Hasil Model terbaik dengan Data Latih dan Data Uji	141
4.6	Pengujian dengan <i>Unseen Data</i>	142

4.7. Perbandingan dengan penelitian terdahulu.....	151
4.8 Perbedaan dari Penelitian tahap awal dan Penelitian tahap akhir	154
4.9 Hasil Penelitian dan Publikasi artikel.....	155
BAB 5 KESIMPULAN DAN SARAN	157
5.1 Kesimpulan.....	157
5.2 Saran	158
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1	Fitur Utama gelombang EKG I.....	6
Gambar 2.2	EKG Subjek SCD	7
Gambar 2.3	EKG Subjek CAD	8
Gambar 2.4	EKG Subjek CHF	8
Gambar 2.5	EKG Subjek VT	9
Gambar 2.6	EKG Subjek NSR	10
Gambar 2.7	<i>Block diagram of the wavenet model</i>	25
Gambar 3.1	Metode yang diusulkan.....	28
Gambar 3.2.	Cywin64 Terminal.....	35
Gambar 3.3.	Implementasi pada program Cygwin64 terminal dalam segmentasi subjek SCD	36
Gambar 3.4.	Hasil segmentasi subjek SCD <i>records</i> 30	36
Gambar 3.5.	Implementasi pada program Cygwin64 terminal dalam segmentasi subjek CAD,CHF, VT dan NSR.....	37
Gambar 3.6	Hasil segmentasi EKG subjek selama 5 menit untuk subjek (a) CAD, (b) CHF, (c) VT, dan (d) NSR	39
Gambar 3.7	Ilustrasi segmentasi EKG 30 menit ke 5 Menit.....	40
Gambar 3.8	Tahapan mendapatkan Interval RR	41
Gambar 3.9.	Hasil <i>Denoising</i> DWT pada subjek SCD <i>records</i> 30m dengan menggunakan <i>wavelet</i> (a)sym3, (b)sym4, dan (c)sym5	45
Gambar 3.10	EKG setelah melalui proses pra-pemrosesan dengan penanda "x" untuk subjek (a) CAD, (b) CHF, (c) VT, (d) SCD, dan (e) NSR.....	48
Gambar 3.11	Ilustrasi Ekstraksi Fitur MRR.....	52
Gambar 3.12	Tahapan persiapan Data	60
Gambar 3.13	Ilustrasi pelabelan Data	62
Gambar 3.14	Data Hasil <i>EncodedLabel</i>	64
Gambar 3.15	Data hasil proses <i>One Hot Encoding</i>	65
Gambar 3.16	Data hasil proses Normalisasi	66

Gambar 3.17	Data latih	67
Gambar 3.18	Data Uji	67
Gambar 3.19	CNN 1D dalam metode yang diusulkan menggunakan model <i>Wavenet</i>	86
Gambar 4.1	Hasil ekstraksi Subjek CAD	88
Gambar 4.2.	(a) Data Latih; (b) Data Uji pada Segmen ke-2.....	89
Gambar 4.3	Klasifikasi Repot Metode pada delapan fitur (a) SVM, (b) DT	92
Gambar 4.4	Klasifikasi Repot Metode pada sebelas fitur (a) SVM, (b) DT	92
Gambar 4.5	13 <i>Confusion Matrix</i> SVM dan DT untuk (a) delapan fitur HRV, (b) Sebelas fitur HRV	94
Gambar 4.6	<i>Confusion Matrix</i> untuk Segmen ke-2 sampai ke-6 untuk sebelas fitur HRV pada Metode SVM.....	96
Gambar 4.7	Rata-rata Nilai Akurasi, sensitivitas, spesitifitas, dan presisi pada Metode SVM dengan dataset delapan dan sebelas fitur HRV	101
Gambar 4.8	<i>Confusion Matrix</i> Metode KNN (a) delapan fitur HRV, (b) sebelas fitur HRV	103
Gambar 4.9	<i>Confusion Matrix</i> Metode KNN Segmen ke2 sampai dengan ke-6 (a) delapan fitur HRV, (b) sebelas fitur HRV.....	105
Gambar 4.10.	Rata-rata nilai akurasi, sensitivitas, spesifisitas dan presisi untuk dataset delapan dan sebelas fitur HRV pada metode KNN	107
Gambar 4.11	<i>Confusion Matrix</i> Metode MLP (a) delapan fitur HRV, (b) sebelas fitur HRV	109
Gambar 4.12	<i>Confusion Matrix</i> Metode MLP Segmen ke2 sampai dengan ke-6 untuk (a) delapan fitur HRV, (b) sebelas fitur HRV.....	111
Gambar 4.13	Rata-rata nilai akurasi, sensitivitas,	

	spesifisitas dan presisi untuk dataset delapan dan sebelas fitur HRV pada metode MLP.....	113
Gambar 4.14	<i>Confusion Matrix</i> Metode RF (a) delapan fitur HRV, (b) sebelas fitur HRV	115
Gambar 4.15	<i>Confusion Matrix</i> Metode RF Segmen ke2 sampai dengan ke-6 untuk (a) delapan fitur HRV, (b) sebelas fitur HRV.....	118
Gambar 4.16	Rata-rata nilai akurasi, sensitivitas, spesifisitas dan presisi untuk <i>dataset</i> delapan dan sebelas fitur HRV pada metode RF	120
Gambar 4.17.	Rata-rata nilai akurasi, sensitivitas, spesifisitas dan presisi untuk lima metode ML (a) delapan fitur HRV, (b) sebelas fitur HRV	123
Gambar 4.18	<i>Mean Test Score 3 Hidden Layer</i>	125
Gambar 4.19	<i>Mean Test Score 5 Hidden Layer</i>	126
Gambar 4.20	<i>Mean Test Score 7 Hidden Layer</i>	127
Gambar 4.21	<i>Mean Tesit Score 9 Hidden Layer</i>	128
Gambar 4.22	Nilai <i>loss</i> dari pengujian pada: (a) Model 1; (b) Model 2; (c) Model 3; dan (d) Model 4	131
Gambar 4.23	Nilai Akurasi dari pengujian pada: (a) Model 1; (b) Model 2; (c) Model 3; dan (d) Model 4	133
Gambar 4.24	Grafik Akurasi dan Loss pada Model Optimal (a) Akurasi, (b) Loss.....	136
Gambar 4.25	<i>Confusion Matrix</i> Metode CNN-Wavenet Segmen pertama sampai dengan ke-6 untuk (a) delapan fitur HRV, (b) sebelas fitur HRV	138
Gambar 4.26	Rata-rata metode optimal berdasarkan nilai Data Latih dan Data Uji.....	142
Gambar 4.27	<i>Confusion Matrix</i> Metode (a) SVM, (b) DT, (b) CNN-Wavenet.....	146
Gambar 4.28	Rata-rata nilai akurasi, sensitivitas,	

spesifisitas dan presisi pada *unseen* data150

DAFTAR TABEL

Tabel 2.1	Penelitian sejenis	12
Tabel 2.2	Confusion Matrix.....	26
Tabel 3.1	Rincian Subjek Data Base	30
Tabel 3.2	Deskripsi segmentasi waktu	35
Tabel 3.3	Rincian Waktu persegmen Record No. 30	36
Tabel 3.3	Deskripsi Penamaan Data.....	39
Tabel 3.4	SNR dari DWT pada subjek SCD	44
Tabel 3.5	RR Interval untuk masing-masing kelas.....	49
Tabel 3.6	Ekstraksi Sebelas Fitur HRV.....	59
Tabel 3.7	SVM Hyperparameter	71
Tabel 3.8	KNN Hyperparameter	72
Tabel 3.9	DT Hyperparameter.....	76
Tabel 3.10	MLP Hyperparameter.....	77
Tabel 3.11	RF Hyperparameter	77
Tabel 3.12	Arsitektur 1D-CNN Wavenet	81
Tabel 3.13	Hyperparameter CNN-Wavenet	83
Tabel 3.14	Rincian Subjek Unseen Data	85
Tabel 4.1	Parameter Optimal pada metode SVM dan DT.....	91
Tabel 4.2	Rata-rata Hasil Akurasi untuk enam segmen metode SVM.....	97
Tabel 4.3	Hasil Sensitivitas pada semua segmen metode SVM.....	98
Tabel 4.4	Hasil Spesifisitas pada semua segmen metode SVM.....	98
Tabel 4.5	Hasil Presisi pada semua segmen metode SVM.....	99
Tabel 4.6	Performa Klasifikasi Menggunakan SVM berdasarkan segmen.....	100
Tabel 4.7	Performa Klasifikasi Menggunakan SVM berdasarkan subjek kelas	101
Tabel 4.8	Parameter Optimal pada metode KNN.....	102
Tabel 4.9	Performa Klasifikasi Menggunakan KNN berdasarkan segmen.....	106
Tabel 4.10	Performa Klasifikasi Menggunakan KNN	

	berdasarkan subjek kelas	107
Tabel 4.11	Parameter Optimal pada metode MLP	108
Tabel 4.12	Performa Klasifikasi Menggunakan MLP berdasarkan segmen.....	112
Tabel 4.13	Performa Klasifikasi Menggunakan MLP berdasarkan subjek kelas	113
Tabel 4.14	Parameter Optimal pada metode RF.....	115
Tabel 4.15	Performa Klasifikasi Menggunakan RF berdasarkan segmen.....	119
Tabel 4.16	Performa Klasifikasi Menggunakan RF berdasarkan subjek kelas	120
Tabel 4.17	Hasil Nilai Akurasi, Sensitivitas, Spesifisitas, dan Presisi pada metode machine learning.....	122
Tabel 4.18	Optimasi parameter pada 3 hidden layer	125
Tabel 4.19	Optimasi parameter pada 5 hidden layer	126
Tabel 4.20	Optimasi parameter pada 7 hidden layer	128
Tabel 4.21	Optimasi parameter pada 9 hidden layer	129
Tabel 4.22	Arsitektur 1D-CNN Wavenet dengan hyperparameter terbaik ...	134
Tabel 4.23	Performa Klasifikasi Menggunakan Model Wavenet 1D-CNN berdasarkan segmen	139
Tabel 4.24	Performa Klasifikasi Menggunakan Model Wavenet 1D-CNN berdasarkan subjek kelas.....	140
Tabel 4.25	Performa Klasifikasi berdasarkan segmen pada unseen data.....	148
Tabel 4.26	Performa Klasifikasi berdasarkan Kelima Subjek.....	149
Tabel 4.27	Hasil perbandingan dengan penelitian terkait	157
Tabel 4.28	Perbedaan Hasil ke akuratan 8 Fitur dan 11 Fitur HRV	204

DAFTAR ISTILAH

CAD	= Coronary Artery Disease	2
CHF	= Congestive Heart Failure	1
CNN	= Convolutional Neural Network	2
DL	= Deep Learning	2
DT	= Decision Tree	2
DWT	= Discrete Wavelet Transform	41
EKG	= Elektrokardiogram	1
FN	= False Negative	26
FP	= False Positive	26
FPR	= False Positive Rate	27
HRV	= Heart Rate Variability	1
KNN	= K-Nearest Neighbor	2
ML	= Machine Learning	2
NADev	= Normalized Absolute Deviation	41
NADiff	= Normalized Absolute Difference	41
NSR	= Normal	1
RF	= Random Forest	2
SCD	= Sudden Cardiac Death	1
SVM	= Support Vector Machine	2
TN	= True Negative	26
TP	= True Positif	25
TPR	= True Positive Rate	27
VF	= Ventrikular Fibrilasi	7
VT	= Ventricular Tachycardia	2
WFDB	= Waveform Database	31

DAFTAR LAMPIRAN

- 1. Dataset yang telah di ekstraksi kedalam difitur HRV**
- 2. Paper Icecos 2019**
- 3. Paper ICIMSI 2023**
- 4. Artikel jurnal yang telah publish di journal Medicina-MDPI**

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Elektrokardiogram (EKG) merupakan salah satu alat diagnostik utama yang digunakan dalam mengevaluasi aktivitas listrik jantung, termasuk detak, ritme dan kondisi kesehatan umum dari organ vital ini. Saat EKG merekam, sinyal listrik dari jantung diubah menjadi grafik yang mencerminkan pola dan karakteristik kardiovaskular selama siklus jantung. Gelombang EKG yang utama adalah gelombang P, Gelombang QRS, dan gelombang T, yang merepresentasikan aktivitas depolarisasi dan repolarisasi jantung [1].

Gelombang QRS menjadi fokus utama dalam analisis sinyal EKG karena gelombang ini mengidentifikasi depolarisasi ventrikel jantung. Pada kondisi normal, interval antara dua gelombang QRS berturut-turut, yang dikenal sebagai interval RR, berlangsung dengan kestabilan tertentu. Namun, ketidaknormalan dalam interval RR ini dapat mengungkapkan adanya gangguan dalam denyut jantung atau dikenal dengan *Heart Rate Variability* (HRV). HRV menggambarkan variasi interval waktu antara detak jantung yang berurutan pada interval RR dengan merepresentasikan waktu antara dua gelombang R berturut-turut pada sinyal EKG. HRV telah menjadi area penelitian yang penting dalam analisis sinyal EKG karena memberikan pengetahuan tentang dinamika aktivitas jantung [2].

Salah satu penelitian yang telah menggunakan HRV dalam memprediksi penyakit jantung yang mematikan adalah *Sudden Cardiac Death* (SCD) dengan panjang gelombang EKG mulai dari 1 sampai dengan 60 menit dengan akurasi maksimum 91.67% [3]. Dalam memprediksi SCD, beberapa penelitian menggunakan data pembandingan dari subjek dengan kondisi normal (NSR) [4], [5] dan dengan kondisi kardiovaskular seperti *Congestive Heart Failure* (CHF) [6]. Kemudian pendekatan yang diambil oleh Rohilia dkk [3] membawa inovasi baru dalam menganalisis SCD. Mereka tidak hanya memasukkan subjek dengan kondisi NSR dan CHF dalam data pembandingan, tetapi juga melibatkan subjek yang

menderita kondisi kardiovaskular lainnya seperti *Coronary Artery Disease* (CAD), dimana CAD yang dilihat dalam data pembanding, dapat meningkatkan kompleksitas model prediksi.

Berdasarkan referensi penelitian Rohilia dkk [3] yang berfokus mengidentifikasi sinyal EKG pada SCD menggunakan HRV dengan empat data pembanding, penelitian ini akan memperluas cakupan dengan menambahkan data pembanding menjadi lima kelompok. Kelompok data pembanding baru ini mencakup individu yang telah didiagnosis menderita *Ventricular Tachycardia* (VT), sebuah kondisi kardiovaskular yang memiliki probabilitas tinggi untuk terjadinya SCD [7].

Penambahan kelompok pembanding VT dalam penelitian ini penting karena kondisi ini memiliki hubungan erat dengan kondisi risiko SCD. Sebelumnya VT telah digunakan memprediksi risiko SCD dengan akurasi mencapai 90.2% [8]. Dengan memasukkan VT sebagai kelompok pembanding dalam analisis HRV, telah digunakan pada penelitian awal dalam memprediksi penyakit jantung.

Penelitian ini memiliki pendekatan inovatif untuk menganalisis HRV menggunakan metode *Deep Learning* (DL). Metode DL digunakan untuk menganalisis fitur HRV dengan tujuan membuktikan deteksi penyakit jantung yang berpotensi kematian (SCD). Penelitian sebelumnya telah menggunakan berbagai Metode *Machine Learning* (ML) seperti *Multilayer Perceptron* (MLP), *k-Nearest Neighbor* (KNN) dengan akurasi, *Support Vector Machine* (SVM), *Decision Tree* (DT), dan *Random Forest* (RF) dengan nilai akurasi berturut-turut 84.28%, 83.33%, 91.67%, dan 89%. Berdasarkan dari nilai akurasi tersebut dan informasi yang telah disampaikan pada penelitian Devi dkk [6], menjadi dasar dari penelitian ini untuk fokus menggunakan metode DL, terutama *Convolutional Neural Network* (CNN) utama karena telah mendapatkan popularitas dalam diagnosis medis berkat kinerja dan efektivitasnya yang unggul dibandingkan algoritma ML lainnya [9]

Penggunaan metode CNN telah menunjukkan hasil yang menjanjikan dalam melakukan klasifikasi sinyal EKG dibandingkan dengan berbagai metode algoritma ML lainnya. Model CNN mencatat kinerja yang sangat baik, karena memberikan capaian akurasi mulai dari 93.53% hingga 99% [10]–[12]. CNN

terkenal dengan kemampuan dalam pengenalan pola, yang mencakup ekstraksi fitur, pengurangan dimensi, dan teknik klasifikasi. Metode CNN memiliki tiga lapisan utama : *input*, *hidden*, dan *output*, dengan semakin dalamnya lapisan meningkatkan kemampuan deteksi dan klasifikasi penyakit jantung [13].

Dengan latar belakang tersebut, pada tahap awal penelitian (proposal penelitian), dataset berhasil diperoleh dengan tambahan subjek pada kasus penyakit jantung dengan durasi 30 menit. Kemudian, dengan dataset tersebut, berhasil dikembangkan model 1D CNN-*Wavenet* yang menggunakan delapan fitur HRV. Model ini mencapai nilai akurasi rata-rata sebesar 99.42%, sensitivitas 97.65%, spesifisitas 99.65%, dan presisi 98.22% [14]. Kinerja model ini terbukti lebih unggul daripada penelitian sebelumnya yang menggunakan metode ML untuk fitur HRV. Meskipun demikian, terdapat keterbatasan pada penelitian awal ini, di mana fitur yang digunakan hanya terfokus pada delapan fitur domain waktu. Selain itu, pengujian hanya dilakukan pada metode ML, sementara belum dilakukan pengujian untuk mengevaluasi kinerja dari metode ML pada *dataset* yang menggunakan delapan fitur tersebut.

Dengan demikian kontribusi penelitian akhir ini adalah :

- Memperluas dataset menjadi sebelas fitur HRV.
- Mengeksplorasi kemampuan model 1D CNN-*Wavenet* dan metode ML dalam konteks klasifikasi penyakit jantung

1.2 Perumusan Masalah

Beberapa model telah dikembangkan oleh beberapa peneliti dalam mengklasifikasi penyakit jantung yang mengarah ke SCD, namun model ini masih dapat dikembangkan untuk meningkatkan nilai akurasi dengan menggunakan model dari DL [6] dan Model dari Metode ML dan menambahkan data pembanding penyakit jantung lainnya dengan ekstraksi fitur HRV [3] dalam memprediksi SCD sehingga pernyataan riset penelitian ini adalah

“Bagaimana meningkatkan nilai akurasi dalam mengklasifikasi sinyal EKG penyakit jantung menggunakan analisis ekstraksi fitur HRV ?”

Untuk menyelesaikan permasalahan tersebut, beberapa isu penting yang akan dipertimbangkan di antaranya :

1. Sejauh mana penambahan tiga fitur HRV pada *dataset* awal dengan delapan fitur HRV dapat meningkatkan tingkat akurasi, sensitivitas, spesifisitas, dan presisi dari metode ML dan DL dalam mengklasifikasikan kasus penyakit jantung?
2. Bagaimana perbandingan kinerja antara metode ML dan DL yang menggunakan delapan fitur HRV dengan model yang diperluas menggunakan sebelas fitur HRV dalam konteks klasifikasi penyakit jantung ?
3. Apakah optimalisasi metode ML dan DL yang dilakukan dapat menjadi alternatif yang sebanding atau lebih unggul dibandingkan dalam mengklasifikasikan penyakit jantung ?

1.3 Tujuan Penelitian

Sesuai dengan latar belakang permasalahan yang ada penelitian ini, maka tujuan dari penelitian ini adalah :

1. Untuk mengevaluasi dampak dari penambahan tiga fitur HRV pada *dataset* awal yang terdiri dari delapan fitur HRV terhadap peningkatan tingkat akurasi, sensitivitas, spesifisitas, dan presisi metode ML dan DL dalam proses klasifikasi penyakit jantung.
2. Untuk membandingkan kinerja antara metode ML dan DL yang menggunakan delapan fitur HRV dengan model yang diperluas menggunakan sebelas fitur HRV dalam konteks klasifikasi penyakit jantung, guna menentukan apakah peningkatan jumlah fitur HRV secara signifikan meningkatkan kualitas prediksi model.
3. Untuk mengevaluasi potensi dan keunggulan optimalisasi metode ML sebagai alternatif atau pendekatan yang sebanding, atau bahkan mungkin lebih unggul, jika dibandingkan dengan DL dalam mengklasifikasikan penyakit jantung.

1.4 Ruang Lingkup Penelitian

Adapun ruang lingkup dalam penelitian ini adalah :

1. Metode yang digunakan adalah metode ML dan DL
2. *Dataset* yang digunakan yaitu SCD, CAD, CHF, VT dan subjek normal
3. *Dataset* di ambil dari *PhysioNet databases* (<https://physionet.org/>)
4. Metode ML yang digunakan berdasarkan referensi yang telah digunakan dari penelitian sebelumnya yaitu MLP, KNN, SVM, DT dan RF
5. Perangkat Lunak yang digunakan adalah *pyhton* dan *cygwin64*

1.5 Sistematika Penulisan

Laporan penelitian ini terdiri dari lima bab yaitu :

BAB 1. Menjelaskan pendahuluan dari penelitian.

BAB 2. Berisikan tentang teori mendasar tentang EKG, HRV, EKG Penyakit Jantung (SCD, CAD, CHF, VT) dan NSR, ML, DL, Evaluasi kinerja klasifikasi, penelitian sejenis.

BAB 3. Menjelaskan tentang langkah kerja penelitian mulai dari studi literatur, *pra*-pemrosesan *dataset*, model klasifikasi dan pengujian model ML dan DL.

BAB 4. Menjelaskan hasil dari penelitian ini.

BAB 5. Menjelaskan kesimpulan dan saran dari penelitian ini.

DAFTAR PUSTAKA

- [1] S. Kaplan Berkaya, A. K. Uysal, E. Sora Gunal, S. Ergin, S. Gunal, and M. B. Gulmezoglu, “A survey on ECG analysis,” *Biomed. Signal Process. Control*, vol. 43, pp. 216–235, 2018.
- [2] K. C. Siontis, P. A. Noseworthy, Z. I. Attia, and P. A. Friedman, “Artificial intelligence-enhanced electrocardiography in cardiovascular disease management,” *Nat. Rev. Cardiol.*, vol. 18, no. 7, pp. 465–478, 2021.
- [3] A. Rohila and A. Sharma, “Detection of sudden cardiac death by a comparative study of heart rate variability in normal and abnormal heart conditions,” *Biocybern. Biomed. Eng.*, vol. 40, no. 3, pp. 1140–1154, 2020.
- [4] E. Ebrahimzadeh *et al.*, “An optimal strategy for prediction of sudden cardiac death through a pioneering feature-selection approach from HRV signal,” *Comput. Methods Programs Biomed.*, vol. 169, pp. 19–36, 2019.
- [5] E. Ebrahimzadeh, M. S. Manuchehri, S. Amoozegar, B. N. Araabi, and H. Soltanian-zadeh, “A time local subset feature selection for prediction of sudden cardiac death from ECG signal A time local subset feature selection for prediction of sudden cardiac death from ECG signal,” no. December, 2017.
- [6] R. Devi, H. Kumar, and D. Kumar, “ScienceDirect A novel multi-class approach for early-stage prediction of sudden cardiac death,” *Integr. Med. Res.*, vol. 39, no. 3, pp. 586–598, 2019.
- [7] A. Mjihad, J. V. Frances-Villora, M. Bataller-Mompean, and A. Rosado-Muñoz, “Ventricular Fibrillation and Tachycardia Detection Using Features Derived from Topological Data Analysis,” *Appl. Sci.*, vol. 12, no. 14, 2022.
- [8] A. Parsi, D. Byrne, M. Glavin, and E. Jones, “Heart rate variability feature selection method for automated prediction of sudden cardiac death,” *Biomed. Signal Process. Control*, vol. 65, p. 102310, 2021.
- [9] R. Kaspal, A. Alsadoon, P. W. C. Prasad, N. A. Al-Saiyd, T. Q. V. Nguyen, and D. T. H. Pham, “A novel approach for early prediction of sudden cardiac death (SCD) using hybrid deep learning,” *Multimed. Tools Appl.*,

- vol. 80, no. 5, pp. 8063–8090, 2021.
- [10] S. Nurmaini *et al.*, “Robust detection of atrial fibrillation from short-term electrocardiogram using convolutional neural networks,” *Futur. Gener. Comput. Syst.*, vol. 113, pp. 304–317, 2020.
- [11] J. Wang, “A deep learning approach for atrial fibrillation signals classification based on convolutional and modified Elman neural network,” *Futur. Gener. Comput. Syst.*, vol. 102, pp. 670–679, 2020.
- [12] U. R. Acharya, H. Fujita, S. L. Oh, Y. Hagiwara, J. H. Tan, and M. Adam, “Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals,” *Inf. Sci. (Ny)*, vol. 415, pp. 190–198, 2017.
- [13] O. Faust, Y. Hagiwara, T. J. Hong, O. S. Lih, and U. R. Acharya, “Deep learning for healthcare applications based on physiological signals: A review,” *Comput. Methods Programs Biomed.*, vol. 161, pp. 1–13, 2018.
- [14] F. Panjaitan, S. Nurmaini, and R. U. Partan, “Accurate Prediction of Sudden Cardiac Death Based on Heart Rate Variability Analysis Using Convolutional Neural Network,” *Medicina (B. Aires)*, vol. 59, no. 8, p. 1394, 2023.
- [15] J. P. Amezcua-Sanchez, M. Valtierra-Rodriguez, H. Adeli, and C. A. Perez-Ramirez, “A Novel Wavelet Transform-Homogeneity Model for Sudden Cardiac Death Prediction Using ECG Signals,” *J. Med. Syst.*, vol. 42, no. 10, 2018.
- [16] C. M. A. Hedayat, H. Chia, X. Zhou, C. Richard., “Supervised ECG Interval Segmentation Using LSTM Neural Network,” *Int’l Conf. Bioinforma. Comput. Biol. BIOCAMP’18*, no. August, p. 71, 2018.
- [17] M. N. R. 1 and F. 1 Annisa Darmawahyuni 1, Siti Nurmaini 1,* , Sukemi 2, Wahyu Caesarendra 3, 4 , Vicko Bhayyu 1, “Deep Learning with a Recurrent Network Structure in the Sequence Modeling of Imbalanced Data for,” pp. 1–12.
- [18] Jasmir *et al.*, “Breast Cancer Classification Using Deep Learning,” *Proc. 2018 Int. Conf. Electr. Eng. Comput. Sci. ICECOS 2018*, vol. 17, pp. 237–

242, 2019.

- [19] <https://physionet.org/>, “PhysioNet.” [Online]. Available: <https://physionet.org/>. [Accessed: 17-Mar-2023].
- [20] “Sudden Cardiac Death Holter Database v1.0.0.” [Online]. Available: <https://physionet.org/content/sddb/1.0.0/>. [Accessed: 17-Mar-2023].
- [21] “Long Term ST Database v1.0.0.” [Online]. Available: <https://physionet.org/content/ltstdb/1.0.0/>. [Accessed: 16-Jun-2023].
- [22] “MIT-BIH Arrhythmia Database v1.0.0.” [Online]. Available: <https://physionet.org/content/mitdb/1.0.0/>. [Accessed: 03-Jun-2022].
- [23] “MIT-BIH Normal Sinus Rhythm Database v1.0.0.” [Online]. Available: <https://www.physionet.org/content/nsrdb/1.0.0/>. [Accessed: 17-Mar-2023].
- [24] A. Parsi, D. Byrne, M. Glavin, and E. Jones, “Heart rate variability feature selection method for automated prediction of sudden cardiac death,” *Biomed. Signal Process. Control*, vol. 65, no. September 2020, p. 102310, 2021.
- [25] X. Wang, Y. Zhang, and R. Zhu, “A brief review on algorithmic fairness,” *Manag. Syst. Eng.*, vol. 1, no. 1, p. 7, 2022.
- [26] F. Emmert-Streib and M. Dehmer, “A machine learning perspective on Personalized Medicine: an automatized, comprehensive knowledge base with ontology for pattern recognition,” *Mach. Learn. Knowl. Extr.*, vol. 1, no. 1, pp. 149–156, 2018.
- [27] D.-C. Vasilescu and M. Filzmoser, “Machine invention systems: a (r) evolution of the invention process?,” *AI Soc.*, vol. 36, pp. 829–837, 2021.
- [28] G. C. Y. Peng *et al.*, “Multiscale modeling meets machine learning: What can we learn?,” *Arch. Comput. Methods Eng.*, vol. 28, pp. 1017–1037, 2021.
- [29] H. Rosenbusch, F. Soldner, A. M. Evans, and M. Zeelenberg, “Supervised machine learning methods in psychology: A practical introduction with annotated R code,” *Soc. Personal. Psychol. Compass*, vol. 15, no. 2, p. e12579, 2021.
- [30] O. Simeone, “A very brief introduction to machine learning with

- applications to communication systems,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 4, no. 4, pp. 648–664, 2018.
- [31] S. Lim, “Software defined network detection system,” *Int. J. Recent Technol. Eng.(IJRTE)*, vol. 8, pp. 1391–1395, 2019.
- [32] L. Antognoli, S. Moccia, L. Migliorelli, S. Casaccia, L. Scalise, and E. Frontoni, “Heartbeat detection by laser doppler vibrometry and machine learning,” *Sensors*, vol. 20, no. 18, p. 5362, 2020.
- [33] B. Rim, N.-J. Sung, S. Min, and M. Hong, “Deep learning in physiological signal data: A survey,” *Sensors*, vol. 20, no. 4, p. 969, 2020.
- [34] H. Wang *et al.*, “Deep Feature Learning for Tibetan Speech Recognition using Sparse Auto-encoder,” in *2015 International Conference on Electrical, Automation and Mechanical Engineering*, 2015, pp. 342–345.
- [35] B. Pyakillya, N. Kazachenko, and N. Mikhailovsky, “Deep learning for ECG classification,” in *Journal of physics: conference series*, 2017, vol. 913, no. 1, p. 12004.
- [36] N. Strodthoff, P. Wagner, T. Schaeffter, and W. Samek, “Deep learning for ECG analysis: Benchmarks and insights from PTB-XL,” *IEEE J. Biomed. Heal. Informatics*, vol. 25, no. 5, pp. 1519–1528, 2020.
- [37] A. Picon *et al.*, “Mixed convolutional and long short-term memory network for the detection of lethal ventricular arrhythmia,” *PLoS One*, vol. 14, no. 5, p. e0216756, 2019.
- [38] L. B. van den Oever *et al.*, “Automatic cardiac structure contouring for small datasets with cascaded deep learning models,” *J. Med. Syst.*, vol. 46, no. 5, p. 22, 2022.
- [39] M. T. Nguyen, B. Van Nguyen, and K. Kim, “Deep feature learning for sudden cardiac arrest detection in automated external defibrillators,” *Sci. Rep.*, vol. 8, no. 1, p. 17196, 2018.
- [40] D. Rincon-Yanez, E. De Lauro, S. Petrosino, S. Senatore, and M. Falanga, “Identifying the Fingerprint of a Volcano in the Background Seismic Noise from Machine Learning-Based Approach,” *Appl. Sci.*, vol. 12, no. 14, p. 6835, 2022.

- [41] Y. Yang, L. Wang, X. Nie, and Y. Wang, “Incipient fault diagnosis of analog circuits based on wavelet transform and improved deep convolutional neural network,” *IEICE Electron. Express*, vol. 18, no. 13, p. 20210174, 2021.
- [42] J. Zhang, J. Mo, X. Ma, J. Huang, and F. Song, “Optical Fiber Vibration Signal Identification Method Based on Improved YOLOv4,” *Sensors*, vol. 22, no. 23, p. 9259, 2022.
- [43] L. Wang, Y. Mu, J. Zhao, X. Wang, and H. Che, “IGRNet: a deep learning model for non-invasive, real-time diagnosis of prediabetes through electrocardiograms,” *Sensors*, vol. 20, no. 9, p. 2556, 2020.
- [44] D. Kolar, D. Lisjak, M. Pajak, and D. Pavković, “Fault diagnosis of rotary machines using deep convolutional neural network with wide three axis vibration signal input,” *Sensors*, vol. 20, no. 14, p. 4017, 2020.
- [45] S. Kiranyaz, T. Ince, and M. Gabbouj, “Personalized monitoring and advance warning system for cardiac arrhythmias,” *Sci. Rep.*, vol. 7, no. 1, p. 9270, 2017.
- [46] J. Peng, D. Hao, H. Liu, J. Liu, X. Zhou, and D. Zheng, “Preliminary study on the efficient electrohysterogram segments for recognizing uterine contractions with convolutional neural networks,” *Biomed Res. Int.*, vol. 2019, 2019.
- [47] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [48] I. Banerjee *et al.*, “Comparative effectiveness of convolutional neural network (CNN) and recurrent neural network (RNN) architectures for radiology text report classification,” *Artif. Intell. Med.*, vol. 97, pp. 79–88, 2019.
- [49] S. Kilicarslan, M. Celik, and Ş. Sahin, “Hybrid models based on genetic algorithm and deep learning algorithms for nutritional Anemia disease classification,” *Biomed. Signal Process. Control*, vol. 63, p. 102231, 2021.
- [50] S. Bringas, R. Duque, A. Nieto-Reyes, C. Tîrnăucă, and J. L. Montaña, “A framework for identifying sequences of interactions that cause usability

- problems in collaborative systems,” *Electronics*, vol. 10, no. 4, p. 388, 2021.
- [51] Z. Huo *et al.*, “Optimal Compensation of MEMS Gyroscope Noise Kalman Filter Based on Conv-DAE and MultiTCN-Attention Model in Static Base Environment,” *Sensors*, vol. 22, no. 19, p. 7249, 2022.
- [52] Y. Meng, L. Lin, Z. Qin, Y. Qu, Y. Qin, and Y. Li, “Biosignal Classification Based on Multi-Feature Multi-Dimensional WaveNet-LSTM Models,” *J. Commun.*, vol. 17, no. 5, pp. 399–404, 2022.
- [53] A. van den Oord *et al.*, “Wavenet: A generative model for raw audio,” *arXiv Prepr. arXiv1609.03499*, 2016.
- [54] N. Kalchbrenner, L. Espeholt, O. Vinyals, and A. Graves, “Conditional image generation with PixelCNN decoders,” *Adv. Neural Inf. Process. Syst.*, 2016.
- [55] G. Liu and J. Zhang, “CNID: research of network intrusion detection based on convolutional neural network,” *Discret. Dyn. Nat. Soc.*, vol. 2020, pp. 1–11, 2020.
- [56] D. O’Shaughnessy, “Review of methods for coding of speech signals,” *EURASIP J. Audio, Speech, Music Process.*, vol. 2023, no. 1, p. 8, 2023.
- [57] H. Cuesta and E. Gómez Gutiérrez, “Voice assignment in vocal quartets using deep learning models based on pitch salience,” *Trans. Int. Soc. Music Inf. Retrieval. 2022; 5 99-112.*, 2022.
- [58] A. Amanlou, A. A. Suratgar, J. Tavoosi, A. Mohammadzadeh, and A. Mosavi, “Single-image reflection removal using deep learning: a systematic review,” *IEEE Access*, vol. 10, pp. 29937–29953, 2022.
- [59] A. Darmawahyuni, S. Nurmaini, and F. Firdaus, “Coronary Heart Disease Interpretation Based on Deep Neural Network,” *Comput. Eng. Appl. J.*, vol. 8, no. 1, pp. 1–12, 2019.
- [60] “PhysioNet.” [Online]. Available: <https://physionet.org/>. [Accessed: 15-Jun-2023].
- [61] “BIDMC Congestive Heart Failure Database v1.0.0.” [Online]. Available: <https://physionet.org/content/chfdb/1.0.0/>. [Accessed: 16-Jun-2023].

- [62] T. F. of the E. S. of C. the N. A. S. of P. Electrophysiology, “Heart rate variability: standards of measurement, physiological interpretation, and clinical use,” *Circulation*, vol. 93, no. 5, pp. 1043–1065, 1996.
- [63] “WFDB quick start for MS-Windows.” [Online]. Available: <https://archive.physionet.org/physiotools/wfdb-windows-quick-start.shtml>. [Accessed: 30-Aug-2023].
- [64] S. Mahdavi, H. Panamtash, Y. Norouzi, and S. Norouzi, “Atrial fibrillation detection method based on converting ECG to signal using both symptoms of AF,” 2020.
- [65] Priyanka Mayapur, “A Review on Detection and Performance Analysis on R-R Interval Methods for ECG ,” *Int. J. Innov. Res. Sci. Eng. Technol.*, vol. 7, no. 11, pp. 11019–11026, 2018.
- [66] A. Elola, E. Aramendi, E. Rueda, U. Irusta, H. Wang, and A. Idris, “Towards the prediction of rearrest during out-of-hospital cardiac arrest,” *Entropy*, vol. 22, no. 7, p. 758, 2020.
- [67] I. Isasi *et al.*, “A Machine Learning-Based Pulse Detection Algorithm for Use During Cardiopulmonary Resuscitation,” in *2021 Computing in Cardiology (CinC)*, 2021, vol. 48, pp. 1–4.
- [68] U. R. Acharya *et al.*, “An integrated index for detection of Sudden Cardiac Death using Discrete Wavelet Transform and nonlinear features,” *Knowledge-Based Syst.*, vol. 83, no. 1, pp. 149–158, 2015.
- [69] M. Adam *et al.*, “Automated characterization of cardiovascular diseases using relative wavelet nonlinear features extracted from ECG signals,” *Comput. Methods Programs Biomed.*, vol. 161, pp. 133–143, 2018.
- [70] P. G. Malghan and M. K. Hota, “A review on ECG filtering techniques for rhythm analysis,” *Res. Biomed. Eng.*, vol. 36, pp. 171–186, 2020.
- [71] A. Kumar, H. Tomar, V. K. Mehla, R. Komaragiri, and M. Kumar, “Stationary wavelet transform based ECG signal denoising method,” *ISA Trans.*, vol. 114, pp. 251–262, 2021.
- [72] A. Darmawahyuni, S. Nurmaini, M. Yuwandini, Muhammad Naufal Rachmatullah, F. Firdaus, and B. Tutuko, “Congestive heart failure

- waveform classification based on short time-step analysis with recurrent network,” *Informatics Med. Unlocked*, vol. 21, 2020.
- [73] A. Ghodrati, B. Murray, and S. Marinello, “RR interval analysis for detection of atrial fibrillation in ECG monitors,” in *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2008, pp. 601–604.
- [74] A. G. Bonomi *et al.*, “Atrial fibrillation detection using a novel cardiac ambulatory monitor based on photo-plethysmography at the wrist,” *J. Am. Heart Assoc.*, vol. 7, no. 15, p. e009351, 2018.
- [75] N. A. Abdul-Kadir, N. M. Safri, and M. A. Othman, “Effect of ECG episodes on parameters extraction for paroxysmal atrial fibrillation classification,” in *2014 IEEE Conference on Biomedical Engineering and Sciences (IECBES)*, 2014, pp. 874–877.
- [76] P. S. Hamilton and W. J. Tompkins, “Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmia database,” *IEEE Trans. Biomed. Eng.*, no. 12, pp. 1157–1165, 1986.
- [77] R. A. Álvarez, A. J. M. Penín, and X. A. V. Sobrino, “A comparison of three QRS detection algorithms over a public database,” *Procedia Technol.*, vol. 9, pp. 1159–1165, 2013.
- [78] S. Rahman and M. A. Rahman, “Assessment of reliability of Hamilton-Tompkins algorithm to ECG parameter detection,” in *Proceedings of the 2012 International Conference on Industrial Engineering and Operations Management Istanbul*, 2012.
- [79] O. Dössel, G. Luongo, C. Nagel, and A. Loewe, “Computer modeling of the heart for ECG interpretation—a review,” *Hearts*, vol. 2, no. 3, pp. 350–368, 2021.
- [80] X. Ji, C. Ning, C. Zhao, and X. Zhang, “Design of the HRV Analysis System Based on AD8232,” *Destech Trans. Eng. Technol. Res. doi*, vol. 10, 2017.
- [81] T. Gronwald, B. Rogers, L. Hottenrott, O. Hoos, and K. Hottenrott, “Correlation properties of heart rate variability during a marathon race in

- recreational runners: potential biomarker of complex regulation during endurance exercise,” *J. Sports Sci. Med.*, vol. 20, no. 4, p. 557, 2021.
- [82] E. Ebrahimzadeh, M. Pooyan, and A. Bijar, “A Novel Approach to Predict Sudden Cardiac Death (SCD) Using Nonlinear and Time-Frequency Analyses from HRV Signals,” vol. 9, no. 2, pp. 1–14, 2014.
- [83] J. M. Pappachan, B. Cassidy, C. J. Fernandez, V. Chandrabalan, and M. H. Yap, “The role of artificial intelligence technology in the care of diabetic foot ulcers: the past, the present, and the future,” *World J. Diabetes*, vol. 13, no. 12, p. 1131, 2022.
- [84] S. Shinomoto, Y. Tsubo, and Y. Marunaka, “Detection and categorization of severe cardiac disorders based solely on heart period measurements,” *Sci. Rep.*, vol. 12, no. 1, p. 17019, 2022.
- [85] B. Debnath, M. O’Brien, S. Kumar, and A. Behera, “A step towards automated functional assessment of activities of daily living,” in *Multimodal AI in healthcare: A paradigm shift in health intelligence*, Springer, 2022, pp. 187–202.
- [86] N. Davy, U. Bin Waheed, A. Koeshidayatullah, and A. El-Husseiny, “Automated Deep Learning (AutoDL) for Facies Prediction: Implementation and Strategy,” in *84th EAGE Annual Conference & Exhibition, 2023*, vol. 2023, no. 1, pp. 1–5.
- [87] D. Mahajan *et al.*, “Performance of an automatic arrhythmia classification algorithm: comparison to the ALTITUDE electrophysiologist panel adjudications,” *Pacing Clin. Electrophysiol.*, vol. 37, no. 7, pp. 889–899, 2014.
- [88] L. Shi, Y. Zhu, Y. Zhang, and Z. Su, “Fault diagnosis of signal equipment on the lanzhou-xinjiang high-speed railway using machine learning for natural language processing,” *Complexity*, vol. 2021, pp. 1–13, 2021.
- [89] Z. Tao, L. Huiling, W. Wenwen, and Y. Xia, “GA-SVM based feature selection and parameter optimization in hospitalization expense modeling,” *Appl. Soft Comput.*, vol. 75, pp. 323–332, 2019.
- [90] A. Tharwat, “Parameter investigation of support vector machine classifier

- with kernel functions,” *Knowl. Inf. Syst.*, vol. 61, pp. 1269–1302, 2019.
- [91] I. S. Al-Mejibli, J. K. Alwan, and H. Abd Dhafar, “The effect of gamma value on support vector machine performance with different kernels,” *Int. J. Electr. Comput. Eng.*, vol. 10, no. 5, p. 5497, 2020.
- [92] J. Zhao, H. Zhuang, and L. Lu, “Heart Rate Variability Analysis Method Based on KNN Classification,” in *Cyber Security Intelligence and Analytics: Proceedings of the 2020 International Conference on Cyber Security Intelligence and Analytics (CSIA 2020), Volume 1*, 2020, pp. 800–806.
- [93] M. Alam, M. M. Islam, M. Rokunojjaman, S. Akter, M. B. Hossain, and J. Uddin, “Electrocardiogram Signal Analysis Based on Statistical Approaches Using K-Nearest Neighbor,” in *International Conference on Bangabandhu and Digital Bangladesh*, 2021, pp. 148–160.
- [94] O. Semenova, G. Carra, G. Lightbody, G. Boylan, E. Dempsey, and A. Temko, “Prediction of short-term health outcomes in preterm neonates from heart-rate variability and blood pressure using boosted decision trees,” *Comput. Methods Programs Biomed.*, vol. 180, p. 104996, 2019.
- [95] S. Buś, K. Jędrzejewski, T. Krauze, and P. Guzik, “Feasibility study on the use of heart rate variability parameters for detection of atrial fibrillation with machine learning techniques,” in *2020 Signal Processing Workshop (SPW)*, 2020, pp. 11–16.
- [96] A. S. Eltrass, M. B. Tayel, and A. I. Ammar, “Automated ECG multi-class classification system based on combining deep learning features with HRV and ECG measures,” *Neural Comput. Appl.*, vol. 34, no. 11, pp. 8755–8775, 2022.
- [97] S. Nematov and Y. Talatov, “A method for classifying ecg signals with different possible states on a multilayer perceptron,” *Tech. Sci. Innov.*, vol. 2020, no. 4, pp. 71–78, 2020.
- [98] R. Shashikant and P. Chetankumar, “Predictive model of cardiac arrest in smokers using machine learning technique based on Heart Rate Variability parameter,” *Appl. Comput. Informatics*, vol. 19, no. 3/4, pp. 174–185,

2023.

- [99] V. G. Biradar, H. C. Nagaraj, S. G. Mohan, and P. K. Pareek, “Industrial Fluids Components Health Management Using Deep Learning,” 2022.
- [100] D. M. W. Powers, “Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation,” *arXiv Prepr. arXiv2010.16061*, 2020.
- [101] B. Knyazev, M. Drozdal, G. W. Taylor, and A. Romero Soriano, “Parameter prediction for unseen deep architectures,” *Adv. Neural Inf. Process. Syst.*, vol. 34, pp. 29433–29448, 2021.
- [102] “MIT-BIH ST Change Database v1.0.0.” [Online]. Available: <https://physionet.org/content/stdb/1.0.0/>. [Accessed: 29-Nov-2023].
- [103] “Apnea-ECG Database v1.0.0.” [Online]. Available: <https://physionet.org/content/apnea-ecg/1.0.0/>. [Accessed: 29-Nov-2023].