

**INTERPRETASI DINI INFARK MIOKARD (SERANGAN JANTUNG)  
MELALUI SINYAL ELEKTROKARDIOGRAM BERBASIS  
*RECURRENT NEURAL NETWORK***



**OLEH :  
ANNISA DARMAWAHYUNI  
09042681822002**

**PROGRAM MAGISTER TEKNIK INFORMATIKA  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS SRIWIJYA  
TAHUN 2019**

**LEMBAR PENGESAHAN**

**INTERPRETASI DINI INFARK MIOKARD (SERANGAN  
JANTUNG) MELALUI SINYAL ELEKTROKARDIOGRAM  
BERBASIS *RECURRENT NEURAL NETWORK***

**TESIS**

Diajukan Untuk Melengkapi Salah Satu Syarat  
Memperoleh Gelar Magister

**OLEH:**

**ANNISA DARMAWAHYUNI  
09042681822002**

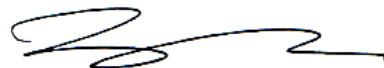
**Pembimbing I**



**Prof. Dr. Ir. Siti Nurmaini, MT**  
196908021994012001

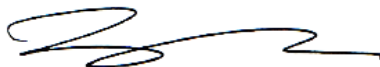
**Palembang, Agustus 2019**

**Pembimbing II**



**Dr. Ir. Sukemi, M.T.**  
196612032006041001

**Mengetahui,  
Koordinator Program Studi Magister Teknik Informatika**



**Dr. Ir. Sukemi, M.T.**  
196612032006041001

## HALAMAN PERSETUJUAN

Hari Kamis tanggal 22 Agustus 2019 telah dilaksanakan ujian Tesis II oleh Magister Teknik Informatika Fakultas Ilmu Komputer Universitas Sriwijaya.

N a m a : Annisa Darmawahyuni  
N I M : 09042681822002  
Judul : Interpretasi Dini Infark Miokard (Serangan Jantung) Melalui Sinyal Elektrokardiogram Berbasis *Recurrent Neural Network*

1. Pembimbing I

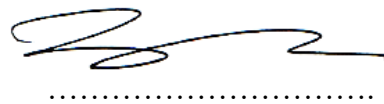
Prof. Dr. Ir. Siti Nurmaini, M.T.  
NIP. 196908021994012001



.....

2. Pembimbing II

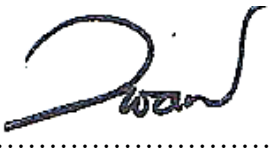
Dr. Ir. Sukemi, M.T.  
NIP. 196612032006041001



.....

3. Penguji I

Dr. Iwan Pahendra, M.T.  
NIP. 197403222002121002



.....

4. Penguji II

Dr. Reza Firsandaya Malik, M.T.  
NIP. 197604252010121001



.....

Mengetahui,  
Koordinator Program Studi Magister Teknik Informatika



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

## LEMBAR PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Annisa Darmawahyuni  
NIM : 09042681822002  
Program Studi : Magister Teknik Informatika  
Judul Tesis : Interpretasi Dini Infark Miokard (Serangan Jantung)  
Melalui Sinyal Elektrokardiogram Berbasis  
*Recurrent Neural Network*

Hasil Pengecekan Software iThenticate/Turnitin : **9 %**

Menyatakan bahwa laporan tesis saya merupakan hasil karya sendiri dan bukan hasil penjiplakan/plagiat. Apabila ditemukan unsur penjiplakan/plagiat dalam laporan tesis ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai dengan ketentuan yang berlaku.

Demikian, pernyataan ini saya buat dengan sebenarnya dan tidak ada paksaan oleh siapapun.



Palembang, Agustus 2019



(Annisa Darmawahyuni)

NIM. 09042681822002

## KATA PENGANTAR

Puji syukur dipanjatkan ke hadirat Allah SWT atas limpahan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan Proposal Tesis dengan judul “Interpretasi Dini Infark Miokard (Serangan Jantung) Melalui Sinyal Elektrokardiogram Berbasis *Recurrent Neural Network*”. Proposal Tesis ini diajukan untuk melengkapi salah satu syarat memperoleh gelar Magister di program studi Magister Teknik Informatika Universitas Sriwijaya.

Penulis menjelaskan mengenai klasifikasi multikelas kondisi jantung normal, infark miokard, kardiomiopati, disritmia, dan blokade cabang berkas (klasifikasi multikelas) dengan menggunakan metode *deep learning*, yaitu *Recurrent Neural Network* (RNN) dengan arsitektur *Long Short-Term Memory* (LSTM). Basis data yang digunakan dalam penelitian ini adalah dataset PhysioNet: *The PTB Diagnostic* yang bisa diakses secara publik.

Penulis berharap Proposal Tesis ini dapat bermanfaat bagi orang banyak, meski masih banyak kekurangan dan jauh dari kesempurnaan. Dalam penyusunan Proposal Tesis ini, penulis banyak mendapat bimbingan, dukungan dan bantuan dari berbagai pihak, baik moril maupun materil, sehingga Proposal Tesis ini dapat diselesaikan. Dengan ketulusan hati, penulis mengucapkan terimakasih kepada:

1. Orang tua, H. Darwis dan Hj. Marsiti, Ali Rozali dan Zaleha atas doa dan ridho yang diberikan kepada penulis.
2. Suami, Iqbal Ramadhan S.Si dan anak tercinta, Muhammad Rafanizan Dhanis atas dukungan, cinta, semangat dan motivasi yang diberikan kepada penulis.
3. Saudara kandung penulis, Fitria S.E dan Muhammad Iqbal, S.T atas semangat dan kontribusi positifnya terhadap penulis.
4. Jaidan Jauhari, M.T selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
5. Dr. Ir. Sukemi, M.T selaku Koordinator Program Studi Magister Teknik Informatika Universitas Sriwijaya dan pembimbing Tesis atas kebijakan dan dukungannya selama pembuatan Proposal Tesis.
6. Prof. Dr. Ir. Siti Nurmaini, M.T. selaku Pembimbing I Tesis yang selalu mengarahkan, memberi nasihat dan dukungan selama pembuatan Proposal Tesis dan publikasi-publikasi sebagai syarat memperoleh gelar Magister.

7. Dr. Iwan Pahendra, M.T selaku Penguji I, dan Dr. Reza Firsandaya Malik, M.T selaku Penguji II yang sejak awal Sidang Proposal, Seminar Hasil, dan Sidang Tesis II memberikan masukan berupa arahan dan saran untuk Proposal Tesis yang lebih baik.
8. Firdaus, M.Kom., dan Muhammad Naufal Rachmatullah, M.T yang memberikan dukungan dan semangat, serta menjadi rekan untuk bertukar ilmu.
9. Fenny Selfania, yang selalu memberikan semangat moralnya sehingga penulis mampu menyelesaikan Tesis.
10. Bapak/Ibu dosen yang ada di Program Studi Magister Teknik Informatika Universitas Sriwijaya
11. Ardina Ariani, S.Kom selaku Admin di Program Studi Magister Teknik Informatika yang membantu seluruh proses administrasi
12. Teman-teman penulis, Renny Amalia, Zaqqi Yamani, Dwi Mei Rita, Ade Iriani, Nurul Afifah, Winda Kurnia, dan Endy Suherman atas dukungan, semangat, dan *sharing* ilmunya.
13. Teman-teman di *Intelligent System Research Group*, Vicko Bhayyu, Andre Herviant, Febby Nurheliza, Rahmi Khoirani, Ferlita Pratiwi, Sicilia Paledya, Tio Artha Nugraha, Varindo Ockta, Muhammad Amir, Ahmad Noviar, Hanif Habibie, dan Muhammad Irham atas dukungan moral, semangat yang mampu membentuk lingkungan positif untuk saling berbagi ilmu.
14. Teman-teman satu angkatan MTI kelas Ganjil 2018, dan
15. Semua pihak yang telah membantu secara langsung maupun secara tidak langsung.

Akhir kata, dengan segala kerendahan hati dan keterbatasan, penulis berharap Proposal Tesis ini menghasilkan sesuatu yang bermanfaat, khususnya bagi Fakultas Ilmu Komputer Universitas Sriwijaya secara langsung ataupun tidak langsung sebagai sumbangan pikiran dalam peningkatan mutu pembelajaran dan penelitian.

Palembang, Agustus 2019

Penulis,  
Annisa Darmwahyuni

# EARLY INTERPRETATION OF MYOCARDIAL INFARCTION VIA ELECTROCARDIOGRAM BASED ON RECURRENT NEURAL NETWORK

**Annisa Darmawahyuni**

## **Abstract**

Cardiac disease is the leading cause of death in developing countries, and it is estimated to be the number one killer in 2020. Among cardiac disease, Myocardial Infarction is the most dangerous form of coronary heart disease with the highest mortality rate. Myocardial Infarction can be diagnosed through an electrocardiogram (ECG), which is a graph of recording the electrical activity of the heart through electrodes placed on the surface of the body. This research aims to classify normal heart conditions with Myocardial Infarction, Cardiomyopathy, Bundle Branch Block, and Dysrhythmias via ECG signals. The database used in this study is Physionet: The Physikalisch-Technische Bundesanstalt (PTB), National Metrology Institute of Germany which can be accessed publicly. The conventional method of machine learning was proposed by previous studies. However, the limitations of the machine learning method are that the model must continue to be given data and involve hand-crafted to produce precise predictions. The machine learning method is still engineered with shallow feature learning architecture. For this study, a classification method with deep learning techniques, Recurrent Neural Network (RNN) based on Long Short-Term Memory (LSTM) is proposed. This research conducted a comparative study with the RNN, LSTM and Bidirectional LSTM methods. From fine-tuning hyperparameter of the three models, LSTM shows the results of classification performance with accuracy, sensitivity, specificity, precision, and F1 score, which are 98.31%, 96.34%, 98.52%, 92.22%, and 94.22% respectively. The LSTM structure and hyperparameters suggested from the results of training and testing for binary and multiclass classification are the softmax activation function in the output layer, loss categorical cross-entropy function, learning-rate of 0.001, with a total of 100 epochs.

## ABSTRAK

Penyakit jantung adalah penyebab utama kematian di negara-negara berkembang dan diperkirakan menjadi pembunuh nomor satu pada tahun 2020. Diantara penyakit jantung, infark miokard merupakan bentuk yang paling berbahaya diantara penyakit jantung koroner dengan angka kematian yang paling tinggi. Infark miokard dapat didiagnosis melalui pemeriksaan elektrokardiogram (EKG) yang merupakan grafik rekaman pencatatan aktivitas listrik jantung melalui elektroda yang ditempatkan di permukaan tubuh. Penelitian ini bertujuan untuk mengklasifikasi kondisi jantung normal dengan infark miokard, kardiomiopati, disritmia, dan blokade cabang berkas melalui sinyal EKG. Basis data yang digunakan dalam penelitian ini adalah Physionet: The *Physikalisch-Technische Bundesanstalt (PTB), National Metrology Institute of Germany* yang bisa diakses secara publik. Metode konvensional *machine learning* (pembelajaran mesin) diusulkan oleh penelitian-penelitian sebelumnya. Namun keterbatasan metode *machine learning* adalah model harus terus diberikan data dan melibatkan campur tangan manusia (*hand-crafted*) untuk menghasilkan prediksi yang akurat. Metode *machine learning* masih direkayasa dengan arsitektur pembelajaran fitur yang dangkal (*shallow feature learning*). Untuk penelitian ini, metode klasifikasi dengan teknik *deep learning* (pembelajaran mendalam), *Recurrent Neural Network (RNN)* berbasis *Long Short-Term Memory (LSTM)* diusulkan. Penelitian ini melakukan studi perbandingan dengan metode RNN, LSTM dan Bidirectional LSTM. Dari *fine-tuning hyperparameter* ketiga model tersebut, LSTM menunjukkan hasil kinerja klasifikasi dengan akurasi, sensitivitas, spesifisitas, presisi, dan F1 score, masing-masing 98,31%, 96,34%, 98,52%, 92,22%, dan 94,22%. Struktur LSTM dan hyperparameter yang disarankan dari hasil pelatihan dan pengujian untuk klasifikasi biner dan multikelas adalah dengan menggunakan fungsi aktivasi sel tanh di input gates, fungsi aktivasi sigmoid di output gates, fungsi aktivasi softmax di lapisan output, fungsi *loss categorical cross entropy*, *learning rate* 0,001, dengan jumlah 100 *epochs*.



## DAFTAR ISI

<b>LEMBAR PENGESAHAN .....</b>	<b>i</b>
<b>HALAMAN PERSETUJUAN.....</b>	<b>ii</b>
<b>LEMBAR PERNYATAAN .....</b>	<b>ii</b>
<b>KATA PENGANTAR.....</b>	<b>ii</b>
<b>ABSTRACT .....</b>	<b>vi</b>
<b>ABSTRAK .....</b>	<b>vii</b>
<b>DAFTAR ISI.....</b>	<b>vviii</b>
<b>DAFTAR GAMBAR.....</b>	<b>x</b>
<b>DAFTAR TABEL .....</b>	<b>xi</b>
<b>DAFTAR ISTILAH .....</b>	<b>xi</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Perumusan Masalah .....	3
1.3 Batasan Masalah .....	4
1.4 Tujuan .....	4
1.5 Metodologi Penulisan .....	5
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>Error! Bookmark not defined.</b>
2.1 Tinjauan Penelitian .....	<b>Error! Bookmark not defined.</b>
2.2 Sinyal Elektrokardiogram .....	<b>Error! Bookmark not defined.</b>
2.3 Infark Miokard .....	<b>Error! Bookmark not defined.</b>
2.4 Artificial Neural Network Pada Infark Miokard .....	<b>Error! Bookmark not defined.</b>
2.5 Recurrent Neural Network .....	<b>Error! Bookmark not defined.</b>
2.5.1 Long Short-Term Memory (LSTM) .....	<b>Error! Bookmark not defined.</b>
2.5.2 Gated Recurrent Unit (GRU) .....	<b>Error! Bookmark not defined.</b>
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>Error! Bookmark not defined.</b>
3.1 Kerangka Kerja Penelitian .....	<b>Error! Bookmark not defined.</b>
3.2 Penelusuran Pustaka.....	<b>Error! Bookmark not defined.</b>
3.3 Persiapan Data .....	<b>Error! Bookmark not defined.</b>
3.4 Pra-pengolahan Sinyal EKG .....	<b>Error! Bookmark not defined.</b>
3.5 Pengklasifikasi RNN-LSTM.....	<b>Error! Bookmark not defined.</b>
3.5.1 Arsitektur & Strukur LSTM.....	<b>Error! Bookmark not defined.</b>

3.5.2 Model Matematis LSTM.....	Error! Bookmark not defined.
3.5.3 Proses Pelatihan .....	Error! Bookmark not defined.
3.5.4 Proses Validasi.....	Error! Bookmark not defined.
3.5.4.1 Validasi Model RNN .....	Error! Bookmark not defined.
3.5.4.2 Validasi Model LSTM .....	Error! Bookmark not defined.
3.5.4.3 Validasi Model Bidirectional LSTM .....	Error! Bookmark not defined.
3.5.5 Proses Pengujian .....	Error! Bookmark not defined.
3.6 Analisis Hasil .....	Error! Bookmark not defined.
3.7 Kesimpulan .....	Error! Bookmark not defined.
<b>BAB IV HASIL DAN ANALISA .....</b>	<b>Error! Bookmark not defined.</b>
4.1 Pengujian Klasifikasi Biner .....	Error! Bookmark not defined.
4.1.1 Hasil Model Vanilla RNN .....	Error! Bookmark not defined.
4.1.2 Hasil Model 1 Lapisan LSTM .....	Error! Bookmark not defined.
4.1.3 Hasil Model 2 dan 3 Lapisan LSTM (Stacked LSTM).....	<b>Error! Bookmark not defined.</b>
4.2 Pengujian Klasifikasi Multikelas .....	Error! Bookmark not defined.
4.2.1 Hasil Model Vanilla RNN .....	Error! Bookmark not defined.
4.2.2 Hasil Model LSTM .....	Error! Bookmark not defined.
4.2.3 Hasil Model Bidirectional LSTM .....	Error! Bookmark not defined.
4.2.3.1 Hasil Validasi Model 1 BLSTM .....	Error! Bookmark not defined.
4.2.3.2 Hasil Validasi Model 2 BLSTM .....	Error! Bookmark not defined.
4.2.3.3 Hasil Validasi Model 3 BLSTM .....	Error! Bookmark not defined.
4.2.3.4 Hasil Validasi Model 4 BLSTM .....	Error! Bookmark not defined.
4.2.3.5 Hasil Validasi Model 5 BLSTM .....	Error! Bookmark not defined.
4.3 Hasil Perbandingan .....	Error! Bookmark not defined.
<b>BAB V KESIMPULAN DAN SARAN .....</b>	<b>Error! Bookmark not defined.</b>
5.1 Kesimpulan .....	Error! Bookmark not defined.
5.2 Saran .....	Error! Bookmark not defined.
<b>DAFTAR PUSTAKA .....</b>	<b>7</b>
<b>JADWAL PENELITIAN.....</b>	<b>Error! Bookmark not defined.</b>
<b>APPENDIX.....</b>	<b>Error! Bookmark not defined.</b>

## DAFTAR GAMBAR

- Gambar 2.1** Elektrokardiogram dengan irama sinus normal **Error! Bookmark not defined.**
- Gambar 2.2** Morfologi Sinyal EKG (Goldberger et al., 2000) **Error! Bookmark not defined.**
- Gambar 2.3** Arsitektur jaringan saraf ..... **Error! Bookmark not defined.**
- Gambar 2.4** Arsitektur pengklasifikasi Convolutional-RNN Strodthoff et al. .... **Error! Bookmark not defined.**
- Gambar 2.5** Arsitektur pengklasifikasi RNN penelitian Goto et. al **Error! Bookmark not defined.**
- Gambar 2.6** Satu modul arsitektur RNN..... **Error! Bookmark not defined.**
- Gambar 2.7** Proses forward dan backward RNN..... **Error! Bookmark not defined.**
- Gambar 3.1** Metodologi Penelitian..... **Error! Bookmark not defined.**
- Gambar 3.2** Sinyal 15-sadapan basis data *The PTB Diagnostic* **Error! Bookmark not defined.**
- Gambar 3.3** Contoh *raw data* pasien 001.heg..... **Error! Bookmark not defined.**
- Gambar 3.4** Contoh *raw data* pasien 001.dat pada 15-sadapan **Error! Bookmark not defined.**
- Gambar 3.5** Proses pra-pengolahan sinyal EKG ..... **Error! Bookmark not defined.**
- Gambar 3.6** Hasil segmentasi sinyal EKG per ukuran window **Error! Bookmark not defined.**  
(4000 samples atau 4 detik) pada 15-sadapan..... **Error! Bookmark not defined.**
- Gambar 3.7** Arsitektur LSTM ..... **Error! Bookmark not defined.**
- Gambar 3.8** Algoritma LSTM (Hochreiter & Schmidhuber, 1997) **Error! Bookmark not defined.**
- Gambar 3.9** Arsitektur LSTM terhadap waktu ..... **Error! Bookmark not defined.**
- Gambar 3.10** Inisialisasi state LSTM ..... **Error! Bookmark not defined.**
- Gambar 3.11** Struktur input, forget, dan output gates LSTM dengan masukan berupa vektor ( $x_t$  dan  $h_{t-1}$ ) ..... **Error! Bookmark not defined.**
- Gambar 3.12** Proses perbaharuan (update) sel memori .... **Error! Bookmark not defined.**
- Gambar 3.13** Proses LSTM hingga menghasilkan output **Error! Bookmark not defined.**
- Gambar 3.14** Proses backward pass dari hasil keluaran forward pass **Error! Bookmark not defined.**
- Gambar 3.15** Proses sel memori yang diupdate pada proses backward pass..... **Error! Bookmark not defined.**

**Gambar 3.16** Perubahan komputasi input dan gate pada backward pass .....**Error! Bookmark not defined.**

**Gambar 3.17** Proses Struktur LSTM untuk  $t - 1$  .....**Error! Bookmark not defined.**

**Gambar 3.18** Proses pengklasifikasi LSTM .....**Error! Bookmark not defined.**

**Gambar 3.19** Jumlah partisi data pelatihan, validasi, dan pengujian**Error! Bookmark not defined.**

**Gambar 3.20** Confusion Matrix 2x2 .....**Error! Bookmark not defined.**

**Gambar 4.1** Box-plot Proses Pelatihan 3 Model Klasifikasi**Error! Bookmark not defined.**

**Gambar 4.2** Box-plot Proses Pengujian 3 Model Klasifikasi**Error! Bookmark not defined.**

**Gambar 4.3** Bar-chart Hasil Rata-rata Proses Pengujian 3 Model Klasifikasi .....**Error! Bookmark not defined.**

## DAFTAR TABEL

TABEL 2.1 Penelitian interpretasi infark miokard (6 tahun terakhir).....	<b>Error! Bookmark not defined.</b>
TABEL 2.2 Elektrokardiogram 12 sadapan (Hampton, 2013).....	<b>Error! Bookmark not defined.</b>
TABEL 2.3 Arsitektur pengklasifikasi Convolutional-RNN penelitian (Lui & Chow, 2018).....	<b>Error! Bookmark not defined.</b>
TABEL 2.4 Kinerja penelitian 1 tahun terakhir .....	<b>Error! Bookmark not defined.</b>
TABEL 3.1 Basis data <i>The PTB Diagnostic</i> (Goldberger et al., 2000).....	<b>Error! Bookmark not defined.</b>
TABEL 3.2 Jumlah Data Sekuensial Hasil Segmentasi 4000 samples atau 4 detik .....	<b>Error! Bookmark not defined.</b>
TABEL 3.3 Tes Diagnostik.....	<b>Error! Bookmark not defined.</b>
TABEL 3.4 Model RNN.....	<b>Error! Bookmark not defined.</b>
TABEL 3.5 Model LSTM .....	<b>Error! Bookmark not defined.</b>
TABEL 3.6 Model Bidirectional LSTM .....	<b>Error! Bookmark not defined.</b>
TABEL 4.1 Hasil Kinerja Evaluasi Model Vanilla RNN.....	<b>Error! Bookmark not defined.</b>
TABEL 4.2 Hasil Kinerja Evaluasi Model 1 Lapisan LSTM.....	<b>Error! Bookmark not defined.</b>
TABEL 4.3 Hasil Kinerja Evaluasi Model 2 dan 3 Lapisan LSTM .....	<b>Error! Bookmark not defined.</b>
TABEL 4.4 Evaluasi Pengujian Klasifikasi Biner Dengan IR = 4.57 .....	<b>Error! Bookmark not defined.</b>
TABEL 4.5 Hasil Kinerja Evaluasi Pelatihan Model Vanilla RNN .....	<b>Error! Bookmark not defined.</b>
TABEL 4.6 Hasil Kinerja Evaluasi Pengujian Model Vanilla RNN.....	<b>Error! Bookmark not defined.</b>
TABEL 4.7 Confusion Matrix Pelatihan Model Vanilla RNN.....	<b>Error! Bookmark not defined.</b>
TABEL 4.8 Confusion Matrix Pengujian Model Vanilla RNN.....	<b>Error! Bookmark not defined.</b>
TABEL 4.9 Hasil Kinerja Evaluasi Pelatihan Model LSTM.....	<b>Error! Bookmark not defined.</b>
TABEL 4.10 Hasil Kinerja Evaluasi Pengujian Model LSTM.....	<b>Error! Bookmark not defined.</b>

**TABEL 4.11** Confusion Matrix Pelatihan Model LSTM>Error! Bookmark not defined.

**TABEL 4.12** Confusion Matrix Pengujian Model LSTM>Error! Bookmark not defined.

**TABEL 4.13** Validasi Model-Model BLSTM.....Error! Bookmark not defined.

**TABEL 4.14** Hasil Kinerja Evaluasi Pelatihan Model 1 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.15** Hasil Kinerja Evaluasi Pengujian Model 1 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.16** Confusion Matrix Pelatihan Model 1 Bidirectional LSTM..... Error! Bookmark not defined.

**TABEL 4.17** Confusion Matrix Pengujian Model 1 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.18** Hasil Kinerja Evaluasi Pelatihan Model 2 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.19** Hasil Kinerja Evaluasi Pengujian Model 2 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.20** Confusion Matrix Pelatihan Model 2 Bidirectional LSTM..... Error! Bookmark not defined.

**TABEL 4.21** Confusion Matrix Pengujian Model 2 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.22** Hasil Kinerja Evaluasi Pelatihan Model 3 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.23** Hasil Kinerja Evaluasi Pengujian Model 3 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.24** Confusion Matrix Pelatihan Model 3 Bidirectional LSTM..... Error! Bookmark not defined.

**TABEL 4.25** Confusion Matrix Pengujian Model 3 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.26** Hasil Kinerja Evaluasi Pelatihan Model 4 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.27** Hasil Kinerja Evaluasi Pengujian Model 4 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.28** Confusion Matrix Pelatihan Model 4 Bidirectional LSTM..... Error! Bookmark not defined.

**TABEL 4.29** Confusion Matrix Pengujian Model 4 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.30** Hasil Kinerja Evaluasi Pelatihan Model 5 Bidirectional LSTM .....Error! Bookmark not defined.

**TABEL 4.31** Hasil Kinerja Evaluasi Pengujian Model 5 Bidirectional LSTM  
.....**Error! Bookmark not defined.**

**TABEL 4.32** Confusion Matrix Pelatihan Model 5 Bidirectional LSTM.....**Error!  
Bookmark not defined.**

**TABEL 4.33** Confusion Matrix Pengujian Model 5 Bidirectional LSTM .....**Error!  
Bookmark not defined.**

**TABEL 4.34** Hasil Kinerja Evaluasi Pengujian 5 Model Bidirectional LSTM  
.....**Error! Bookmark not defined.**

**TABEL 4.35** Hasil Perbandingan Penelitian Klasifikasi Infark Miokard 5 Tahun  
Terakhir .....**Error! Bookmark not defined.**

## DAFTAR ISTILAH

RNN	= Recurrent Neural Network
LSTM	= Long Short-Term Memory
BLSTM	= Bidirectional Long Short-Term Memory
EKG	= Elektrokardiogram
SVM	= Support Vector Machine
ANN	= Artificial Neural Network
Learning Rate	= Tingkat Pembelajaran Jaringan Saraf
Cross Entropy	= Fungsi Loss (Error)
Epochs	= Iterasi dalam satu fase forward dan backward
Optimizer	= Metode optimisasi Jaringan Saraf
Lead	= Sadapan
Input Layer	= Lapisan Masukan
Output Layer	= Lapisan Keluaran
Hidden Layer	= Lapisan Tersembunyi
Tanh, Sigmoid, Softmax	= Fungsi Aktivasi
Confusion Matrix	= Matriks Konfusi (Klasifikasi)
True Positive	= Aktual Sakit, Prediksi Sakit
True Negative	= Aktual Sehat, Prediksi Sehat
False Positive	= Aktual Sehat, Prediksi Sakit
False Negative	= Aktual Sakit, Prediksi Sehat



# BAB I

## PENDAHULUAN

Bab ini berisi latar belakang dilakukannya penelitian yang berjudul “Interpretasi Dini Infark Miokard (Serangan Jantung) Melalui Sinyal Elektrokardiogram Berbasis *Recurrent Neural Network*”. Latar belakang penelitian ini adalah bagaimana cara sistem mengklasifikasi kelainan jantung normal dengan *Myocardial Infarction* (infark miokard), *Cardiomyopathy* (kardiomiopati), *Dysrhythmia* (disritmia), dan *Bundle branch block* (blokade cabang berkas) melalui sinyal elektrokardiogram (EKG). Topik penyakit jantung diangkat dalam penelitian ini dikarenakan penyakit ini merupakan pembunuh nomor satu di dunia. Kelainan jantung akan dipelajari oleh algoritma pengklasifikasi melalui sinyal EKG. Penerapan *deep learning* sebagai algoritma pengklasifikasi diimplementasikan agar fitur dipelajari secara otomatis oleh algoritma tanpa perlu campur tangan manusia. Metode *deep learning* yang digunakan dalam penelitian ini adalah *Recurrent Neural Network* (RNN).

### 1.1 Latar Belakang

222 (Murray et al., 1994)(Nursalim, et al., 2013). Hasil Riset Kesehatan Dasar Kementerian Kesehatan RI tahun 2013 menjelaskan bahwa penyakit jantung yang paling umum terjadi pada orang dewasa adalah penyakit jantung koroner. Jumlah prevalensi penyakit jantung koroner di Indonesia diperkirakan sekitar 883.447 atau sebesar 0.5 persen (Badan Penelitian dan Pengembangan Kesehatan, 2013). Diantara beberapa jenis penyakit jantung koroner, infark miokard merupakan bentuk yang paling berbahaya diantara penyakit jantung koroner dengan angka kematian yang paling tinggi (Alwi, 2009).

Infark miokard dapat didiagnosis melalui pemeriksaan elektrokardiogram (EKG) (Thygesen et al., 2007). EKG merupakan grafik rekaman pencatatan aktivitas listrik jantung melalui elektroda yang ditempatkan di permukaan tubuh (Ricardo et al., 2009). Sinyal EKG memiliki lima bentuk gelombang yang berbeda

untuk setiap siklus jantung; yaitu gelombang P, kompleks QRS, dan gelombang T (Fleming, 2012). Pada pasien dengan kondisi jantung normal, lima bentuk gelombang tersebut menunjukkan bentuk yang sesuai, tidak ada morfologi. Namun berbeda dengan pasien dengan kondisi infark miokard, perubahan EKG dapat diamati dengan khas, yaitu panjangnya interval ST, elevasi ST dan perubahan bentuk gelombang T adalah beberapa indikator adanya infark miokard pada pasien (Zimetbaum & Josephson, 2003).

Interpretasi dini infark miokard melalui sinyal EKG merupakan tantangan yang sulit (Mawri et al., 2016). Berbagai algoritma dan metode konvensional telah diusulkan untuk mendeteksi secara otomatis infark miokard dari rekaman sinyal EKG, yaitu *bat algorithm* (Kora & Kalva, 2015), *multi resolution wavelet* (Remya, Indiradevi, & Babu, 2016), dan *wavelet transform* (M. Kumar, Pachori, & Acharya, 2017). Sebagian besar dari metode tersebut mengekstrak fitur yang relevan dari morfologi sinyal EKG yang merupakan indikasi infark miokard, seperti morfologi interval ST, amplitudo ST dan interval RR (Arif, Malagore, & Afsar, 2012)(Acharya et al., 2017). Kebanyakan metode tersebut melatih pengklasifikasi biner, dan menghasilkan kinerja yang tinggi (Banerjee & Mitra, 2014) (M. Kumar et al., 2017).

Pengklasifikasi biner tersebut memiliki batasan ketika diaplikasikan dan diterapkan untuk diuji coba pada pasien penyakit jantung jenis lain selain infark miokard, dimana hasil pengklasifikasi nya tetap menunjukkan kondisi infark miokard (Lui & Chow, 2018). Hal ini dikarenakan semua jenis penyakit jantung (gagal jantung, kardiomiopati, disritmia, blokade cabang berkas, dan lain-lain) dianggap satu kelas “others” (Lui & Chow, 2018). Pendekatan lain menggunakan metode konvensional *machine learning* seperti *support vector machine* (SVM) diterapkan untuk klasifikasi biner yang juga menghasilkan kinerja yang tinggi (Sharma & Sunkaria, 2018). Namun, keterbatasan metode *machine learning* adalah model harus terus diberikan data dan melibatkan campur tangan manusia (*hand-crafted*) untuk menghasilkan prediksi yang akurat. Metode *machine learning* masih direkayasa dengan arsitektur pembelajaran fitur yang dangkal (*shallow feature learning*) (Pyakillya, Kazachenko, & Mikhailovsky, 2017).

Beberapa tahun terakhir, metode *deep learning* telah menghasilkan kinerja yang baik dan menunjukkan klasifikasi yang lebih unggul dibandingkan dengan metode konvensional *machine learning* (Guo et al., 2016). Hal ini dikarenakan karena teknik *deep learning* mempelajari fitur secara otomatis dan mampu mempelajari metode komputasinya sendiri, tanpa perlu mengekstraksi fitur campur tangan manusia (Pyakillya et al., 2017).

Beberapa contoh teknik deep learning yang digunakan untuk pemrosesan sinyal EKG antara lain *convolutional neural network* (Rajpurkar, Hannun, Haghpanahi, Bourn, & Ng, 2017), *stacked auto encoders* (Vincent, Larochelle, Bengio, & Manzagol, 2008), *deep belief network* (Huanhuan & Yue, 2014), *deep boltzmann machine* (Mathews, Kambhamettu, & Barner, 2018), dan *recurrent neural network* (Lui & Chow, 2018)(Strodthoff & Strodthoff, 2018). Salah satu metode *deep learning* yang diusulkan pada penelitian ini adalah *Recurrent Neural Network* (RNN). Hal ini dikarenakan algoritma RNN bekerja untuk memproses data yang bersifat sekuensial. Hal ini selaras dengan data sinyal EKG yang sekuensial dimana mengasumsikan bahwa input dan output tergantung satu sama lain (Schmidhuber, 2015).

## 1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, maka perumusan masalah pada penelitian ini adalah bagaimana membuat sistem interpretasi untuk mengklasifikasikan kondisi jantung normal dengan infark miokard, kardiomiopati, disritmia, dan blokade cabang berkas. Permasalahan dalam penelitian ini dirumuskan sebagai berikut:

1. Bagaimana cara melakukan pra-pengolahan data sinyal EKG untuk menginterpretasi kondisi jantung normal dengan kondisi jantung infark miokard, kardiomiopati, disritmia, dan blokade cabang berkas?
2. Bagaimana menganalisis struktur RNN untuk mengklasifikasi kondisi jantung normal dengan kondisi jantung infark miokard, kardiomiopati, disritmia, dan blokade cabang berkas melalui sinyal EKG?

3. Bagaimana mengukur kinerja pengklasifikasi Recurrent Neural Network berdasarkan parameter *performance metrics* (akurasi, sensitivitas, spesifisitas, presisi, dan F1 score)?

### 1.3 Batasan Masalah

Batasan masalah dalam sistem interpretasi yang dirancang pada penelitian ini adalah:

1. Sistem interpretasi hanya berupa simulasi untuk mengklasifikasikan kelainan jantung melalui sinyal EKG.
2. Penyakit yang diklasifikasi terdiri dari 5 kelas kondisi jantung, yaitu kondisi jantung normal, infark miokard, kardiomiopati, disritmia, dan blockade cabang berkas.
3. Dataset yang digunakan merupakan data sinyal elektrokardiogram yang diambil dari dataset publik Physionet: *The Physikalisch-Technische Bundesanstalt (PTB) Diagnostic Database* (Goldberger et al., 2000). Jumlah dataset terdiri dari 549 rekaman EKG yang diambil dari 294 pasien.
4. Arsitektur metode Recurrent Neural Network yang digunakan adalah Long Short-Term Memory.
5. Pra-pengolahan sinyal EKG untuk penentuan window size adalah 4 detik berdasarkan penelitian Strodthoff et al. (Strodthoff & Strodthoff, 2018).

### 1.4 Tujuan

Tujuan dalam penelitian ini adalah sebagai berikut:

1. Melakukan proses pra-pengolahan data sinyal elektrokardiogram untuk menginterpretasi kondisi jantung normal dengan kondisi jantung infark miokard, kardiomiopati, disritmia, dan blokade cabang berkas.
2. Membuat dan menganalisis struktur Recurrent Neural Network dalam mengklasifikasi kondisi jantung normal dengan kondisi jantung infark miokard, kardiomiopati, disritmia, dan blokade cabang berkas.

3. Mengukur kinerja pengklasifikasi Recurrent Neural Network berdasarkan parameter *performance metrics* (akurasi, sensitivitas, spesifisitas, presisi, dan F1 score).

## 1.5 Metodologi Penulisan

Metodologi penulisan pada penelitian ini terdiri dari lima bab sebagai berikut:

### BAB I : PENDAHULUAN

Bab I berisi pendahuluan berupa latar belakang, perumusan masalah, tujuan dan manfaat dari topik yang dipilih berupa interpretasi dini infark miokard melalui sinyal elektrokardiogram dengan metode RNN.

### BAB II : TINJAUAN PUSTAKA

Bab II berisi kerangka teori dan pustaka yang berhubungan dengan berupa interpretasi dini infark miokard melalui sinyal elektrokardiogram dengan metode RNN yang mengacu pada beberapa penelitian jurnal publikasi.

### BAB III : METODOLOGI PENELITIAN

Bab III berisi metodologi yang menjelaskan secara bertahap dan terperinci tentang langkah-langkah yang digunakan untuk mencari, mengumpulkan dan menganalisa kaitan interpretasi dini infark miokard melalui sinyal elektrokardiogram. Metodologi ini menjelaskan pendekatan atau algoritma RNN, serta model yang digunakan sehingga tujuan dari penulisan dapat tercapai.

### BAB IV : HASIL DAN ANALISA SEMENTARA

Bab IV berisi hasil pengujian yang telah dilakukan, data-data yang diambil dari pengujian tersebut akan dianalisa menggunakan berbagai macam teknik, selain itu di bab ini juga membahas kevalidasian dari sistem yang telah dibuat.

### BAB V : KESIMPULAN

BAB V berisi tentang kesimpulan mengenai hasil dan analisa dari pengolahan data sinyal EKG untuk menginterpretasi kelainan jantung infark miokard menggunakan metode *deep learning*, yaitu RNN dengan arsitektur LSTM dan Bidirectional LSTM. Bab ini juga merupakan jawaban dari setiap tujuan yang ingin dicapai.

## DAFTAR PUSTAKA

- Acharya, U, R., Fujita, H., Oh, S, L., Hagiwara, Y., Tan, J, H., & Adam, M, (2017), Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals, *Information Sciences*, 415, 190–198,
- Alpert, J, S., Thygesen, K., Antman, E., & Bassand, J, P, (2000), Myocardial infarction redefined--a consensus document of The Joint European Society of Cardiology/American College of Cardiology Committee for the redefinition of myocardial infarction, *Journal of the American College of Cardiology*, 36(3), 959–969,
- Alwi, I, (2009), Infark Miokard Akut Dengan Elevasi ST, *Buku Ajar Ilmu Penyakit Dalam*, 1741–1756,
- Amato, F., López, A., Peña-Méndez, E, M., Vá\vnhara, P., Hampl, A., & Havel, J, (2013), *Artificial neural networks in medical diagnosis*, Elsevier,
- Arif, M., Malagore, I, A., & Afsar, F, A, (2012), Detection and localization of myocardial infarction using k-nearest neighbor classifier, *Journal of Medical Systems*, 36(1), 279–289,
- Badan Penelitian dan Pengembangan Kesehatan, (2013), Riset Kesehatan Dasar (Rieskesdas) 2013, *Laporan Nasional 2013*, <https://doi.org/10.24063/risetkesehatan.kemkes.go.id/1> Desember 2013
- Banerjee, S., & Mitra, M, (2014), Application of cross wavelet transform for ECG pattern analysis and classification, *IEEE Transactions on Instrumentation and Measurement*, 63(2), 326–333,
- Bax, J, J., Baumgartner, H., Ceconi, C., Dean, V., Fagard, R., Funck-Brentano, C., ... others, (2012), Third universal definition of myocardial infarction, *Journal of the American College of Cardiology*, 60(16), 1581–1598,
- Beasley, J, W., & Grogan, E, W, (2012), *Guide to Basic Electrocardiography*, Springer Science & Business Media,
- Bhaskar, N, A, (2015), Performance analysis of support vector machine and neural networks in detection of myocardial infarction, *Procedia Computer Science*, 46, 20–30,

- Bullinaria, J, A, (2015), *Recurrent neural networks*,
- Choi, K., Fazekas, G., Sandler, M., & Cho, K, (2017), Convolutional recurrent neural networks for music classification, *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2392–2396,
- Darmawahyuni, A, (2019), Coronary Heart Disease Interpretation Based on Deep Neural Network, *Computer Engineering and Applications Journal*, 8(1),
- Faust, O., Shenfield, A., Kareem, M., San, T, R., Fujita, H., & Acharya, U, R, (2018), Automated detection of atrial fibrillation using long short-term memory network with RR interval signals, *Computers in Biology and Medicine*, 102, 327–335,
- Fleming, J, S, (2012), *Interpreting the electrocardiogram*, Springer Science & Business Media,
- Gacek, A., & Pedrycz, W, (2011), *ECG signal processing, classification and interpretation: a comprehensive framework of computational intelligence*, Springer Science & Business Media,
- Glorot, X., & Bengio, Y, (2010), Understanding the difficulty of training deep feedforward neural networks, *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, 249–256,
- Goldberg, Y, (2016), A primer on neural network models for natural language processing, *Journal of Artificial Intelligence Research*, 57, 345–420,
- Goldberger, A, L., Amaral, L, A, N., Glass, L., Hausdorff, J, M., Ivanov, P, C., Mark, R, G., ... Stanley, H, E, (2000), PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals, *Circulation*, 101(23), e215--e220,
- Goldberger, A, L., Goldberger, Z, D., & Shvilkin, A, (2017), *Clinical Electrocardiography: A Simplified Approach E-Book*, Elsevier Health Sciences,
- Goto, S., Kimura, M., Katsumata, Y., Goto, S., Kamatani, T., Ichihara, G., ... Sano, M, (2019), Artificial intelligence to predict needs for urgent revascularization from 12-leads electrocardiography in emergency patients, *PloS One*, 14(1),



e0210103,

- Graves, A., & Schmidhuber, J, (2005), Framewise phoneme classification with bidirectional LSTM and other neural network architectures, *Neural Networks*, 18(5–6), 602–610,
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M, S, (2016), Deep learning for visual understanding: A review, *Neurocomputing*, 187, 27–48,
- Hampton, J, R, (2013), *The ECG Made Easy E-Book*, Elsevier Health Sciences,
- Hochreiter, S., & Schmidhuber, J, (1997), Long short-term memory, *Neural Computation*, 9(8), 1735–1780,
- Huanhuan, M., & Yue, Z, (2014), Classification of electrocardiogram signals with deep belief networks, *Computational Science and Engineering (CSE), 2014 IEEE 17th International Conference On*, 7–12,
- Isma'eel, H, A., Cremer, P, C., Khalaf, S., Almedawar, M, M., Elhajj, I, H., Sakr, G, E., & Jaber, W, A, (2016), Artificial neural network modeling enhances risk stratification and can reduce downstream testing for patients with suspected acute coronary syndromes, negative cardiac biomarkers, and normal ECGs, *The International Journal of Cardiovascular Imaging*, 32(4), 687–696,
- Keshtkar, A., Seyedarabi, H., Sheikhzadeh, P., & Rasta, S, H, (2013), Discriminant analysis between myocardial infarction patients and healthy subjects using Wavelet Transformed signal averaged electrocardiogram and probabilistic neural network, *Journal of Medical Signals and Sensors*, 3(4), 225,
- Khan, M, G, (2008), *Rapid ECG interpretation*, Springer Science & Business Media,
- Kora, P., & Kalva, S, R, (2015), Improved Bat algorithm for the detection of myocardial infarction, *SpringerPlus*, 4(1), 666,
- Kumar, A., Irsoy, O., Ondruska, P., Iyyer, M., Bradbury, J., Gulrajani, I., ... Socher, R, (2016), Ask me anything: Dynamic memory networks for natural language processing, *International Conference on Machine Learning*, 1378–1387,
- Kumar, M., Pachori, R, B., & Acharya, U, R, (2017), Automated diagnosis of myocardial infarction ECG signals using sample entropy in flexible analytic

- wavelet transform framework, *Entropy*, 19(9), 488,
- Lui, H, W., & Chow, K, L, (2018), Multiclass classification of myocardial infarction with convolutional and recurrent neural networks for portable ECG devices, *Informatics in Medicine Unlocked*, 13, 26–33,
- Mathews, S, M., Kambhamettu, C., & Barner, K, E, (2018), A novel application of deep learning for single-lead ECG classification, *Computers in Biology and Medicine*, 99, 53–62,
- Mawri, S., Michaels, A., Gibbs, J., Shah, S., Rao, S., Kugelmass, A., ... others, (2016), The comparison of physician to computer interpreted electrocardiograms on ST-elevation myocardial infarction door-to-balloon times, *Critical Pathways in Cardiology*, 15(1), 22–25,
- Mosley, L, (2013), *A balanced approach to the multi-class imbalance problem*,
- Murray, C, J, L., Lopez, A, D., Organization, W, H., & others, (1994), *Global comparative assessments in the health sector: disease burden, expenditures and intervention packages*,
- Nordgaard-Andersen, I, (1991), Automatic computerized ECG interpretation, *Ugeskrift for Laeger*, 153(15), 1049–1051,
- Nursalim, A., Suryaatmadja, M., & Panggabean, M, (2013), Potential clinical application of novel cardiac biomarkers for acute myocardial infarction, *Acta Med Indones*, 45(3), 240–250,
- Pascanu, R., Mikolov, T., & Bengio, Y, (2013), On the difficulty of training recurrent neural networks, *International Conference on Machine Learning*, 1310–1318,
- Pyakillya, B., Kazachenko, N., & Mikhailovsky, N, (2017), Deep learning for ECG classification, *Journal of Physics: Conference Series*, 913(1), 12004,
- Qin, Q., Li, J., Zhang, L., Yue, Y., & Liu, C, (2017), Combining low-dimensional wavelet features and support vector machine for arrhythmia beat classification, *Scientific Reports*, 7(1), 6067,
- Quang, D., & Xie, X, (2016), DanQ: a hybrid convolutional and recurrent deep neural network for quantifying the function of DNA sequences, *Nucleic Acids*

*Research*, 44(11), e107--e107,

- Rajpurkar, P., Hannun, A, Y., Haghpanahi, M., Bourn, C., & Ng, A, Y, (2017), Cardiologist-level arrhythmia detection with convolutional neural networks, *ArXiv Preprint ArXiv:1707.01836*,
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G.-Z, (2017), Deep learning for health informatics, *IEEE Journal of Biomedical and Health Informatics*, 21(1), 4–21,
- Remya, R, S., Indiradevi, K, P., & Babu, K, K, A, (2016), Classification of myocardial infarction using multi resolution wavelet analysis of ECG, *Procedia Technology*, 24, 949–956,
- Ricardo, R, A., Bassani, R, A., & Bassani, J, W, M, (2009), A simple laboratory method for teaching how electrocardiogram is generated, *World Congress on Medical Physics and Biomedical Engineering, September 7-12, 2009, Munich, Germany*, 385–387,
- Rout, A, K., Dash, P, K., Dash, R., & Bisoi, R, (2017), Forecasting financial time series using a low complexity recurrent neural network and evolutionary learning approach, *Journal of King Saud University-Computer and Information Sciences*, 29(4), 536–552,
- Schmidhuber, J, (2015), Deep learning in neural networks: An overview, *Neural Networks*, 61, 85–117,
- Schuster, M., & Paliwal, K, K, (1997), Bidirectional recurrent neural networks, *IEEE Transactions on Signal Processing*, 45(11), 2673–2681,
- Shah, A, P., & Rubin, S, A, (2007), Errors in the computerized electrocardiogram interpretation of cardiac rhythm, *Journal of Electrocardiology*, 40(5), 385–390,
- Sharma, L, D., & Sunkaria, R, K, (2018), Inferior myocardial infarction detection using stationary wavelet transform and machine learning approach, *Signal, Image and Video Processing*, 12(2), 199–206,
- Singh, S., Pandey, S, K., Pawar, U., & Janghel, R, R, (2018), Classification of ECG Arrhythmia using Recurrent Neural Networks, *Procedia Computer Science*,

132, 1290–1297,

- Sinha, R., & others, (2012), *An Approach for Classifying ECG Arrhythmia Based on Features Extracted from EMD and Wavelet Packet Domains*,
- Stojanovski, D., Strezoski, G., Madjarov, G., & Dimitrovski, I, (2016), Deep learning architecture for twitter sentiment analysis, *Proceedings of the 10th International Workshop on Semantic Evaluation (SemEval-2016)*, 149–154,
- Strodthoff, N., & Strodthoff, C, (2018), Detecting and interpreting myocardial infarctions using fully convolutional neural networks, *ArXiv Preprint ArXiv:1806.07385*,
- Thygesen, K., Alpert, J, S., White, H, D., & others, (2007), Universal definition of myocardial infarction, *Journal of the American College of Cardiology*, 50(22), 2173–2195,
- Tripathy, R, K., Sharma, L, N., & Dandapat, S, (2014), A new way of quantifying diagnostic information from multilead electrocardiogram for cardiac disease classification, *Healthcare Technology Letters*, 1(4), 98–103,
- Tsai, P,-F, J., Chen, P,-C., Chen, Y,-Y., Song, H,-Y., Lin, H,-M., Lin, F,-M., & Huang, Q,-P, (2016), Length of hospital stay prediction at the admission stage for cardiology patients using artificial neural network, *Journal of Healthcare Engineering*, 2016,
- Vincent, P., Larochelle, H., Bengio, Y., & Manzagol, P,-A, (2008), Extracting and composing robust features with denoising autoencoders, *Proceedings of the 25th International Conference on Machine Learning*, 1096–1103,
- Wiatowski, T., & Bölcskei, H, (2018), A mathematical theory of deep convolutional neural networks for feature extraction, *IEEE Transactions on Information Theory*, 64(3), 1845–1866,
- Wiener, C., Fauci, A, S., Braunwald, E., Kasper, D, L., Hauser, S, L., Longo, D, L., ... Loscalzo, J, (2008), *Harrison's principles of internal medicine, self-assessment and board review*, McGraw Hill Professional,
- Wu, J, F., Bao, Y, L., Chan, S,-C., Wu, H, C., Zhang, L., & Wei, X,-G, (2016), Myocardial infarction detection and classification—A new multi-scale deep

feature learning approach, *Digital Signal Processing (DSP), 2016 IEEE International Conference On*, 309–313,

Zen, H., & Sak, H, (2015), Unidirectional long short-term memory recurrent neural network with recurrent output layer for low-latency speech synthesis, *Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference On*, 4470–4474,

Zimetbaum, P, J., & Josephson, M, E, (2003), Use of the electrocardiogram in acute myocardial infarction, *New England Journal of Medicine*, 348(10), 933–940,