



TUGAS AKHIR - KS141501

# KLASIFIKASI PROGNOSIS PASIEN ICU MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR MULTIFRACTAL DETRENDED FLUCTUATION ANALYSIS (MFDFA)

*PROGNOSIS CLASSIFICATION OF ICU PATIENTS  
USING ARTIFICIAL NEURAL NETWORK (ANN)  
BASED ON MULTIFRACTAL DETRENDED  
FLUCTUATION ANALYSIS (MFDFA) FEATURE  
EXTRACTION*

RISHA ZAHRA ADITYA  
NRP 05211440000114

Dosen Pembimbing I  
Edwin Riksakomara, S.Kom, M.T

Dosen Pembimbing II  
Faizal Mahananto, S.Kom, M.Eng, Ph.D

DEPARTEMEN SISTEM INFORMASI  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember  
Surabaya 2018





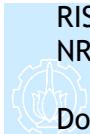
ber



## TUGAS AKHIR - KS141501



# KLASIFIKASI PROGNOSIS PASIEN ICU MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR MULTIFRACTAL DETRENDED FLUCTUATION ANALYSIS (MFDFA)



RISHA ZAHRA ADITYA  
NRP 05211440000114

Dosen Pembimbing I  
Edwin Riksakomara, S.Kom, M.T

Dosen Pembimbing II  
Faizal Mahananto, S.Kom, M.Eng, Ph.D







opember



## FINAL PROJECT - KS141501

# PROGNOSIS CLASSIFICATION OF ICU PATIENTS USING NEURAL NETWORK (ANN) BASED ON MULTIFRACTAL DETRENDED FLUCTUATION ANALYSIS (MFDFA) FEATURE EXTRACTION

RISHA ZAHRA ADITYA  
NRP 05211440000114

Supervisors I  
Edwin Riksakomara, S.Kom, M.T

Supervisors II  
Faizal Mahananto, S.Kom, M.Eng, Ph.D

INFORMATION SYSTEMS DEPARTEMEN  
Information Technology and Communication Faculty  
Sepuluh Nopember Institut of Technology  
Surabaya 2018



opember





**LEMBAR PENGESAHAN**  
**KLASIFIKASI PROGNOSIS PASIEN ICU**  
**MENGGUNAKAN ARITIFICAL NEURAL NETWORK**  
**(ANN) BERDASARKAN EKSTRAKSI FITUR**  
**MULTIFRACTAL DETRENDED FLUCTUATION**  
**ANALYSIS (MFdfa)**

**TUGAS AKHIR**  
Disusun Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer  
pada

Departemen Sistem Informasi  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember

Oleh:

**RISHA ZAHRA ADITYA**  
NRP. 05211440000114

Surabaya, Juli 2018

**KEPALA**  
**DEPARTEMEN SISTEM INFORMASI**

**Dr. Ir. Aris Tjahyanto, M.Kom.**  
**NIP.19650310 199102 1 001**



## LEMBAR PERSETUJUAN

# KLASIFIKASI PROGNOSIS PASIEN ICU MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR MULTIFRACTAL DETRENDED FLUCTUATION ANALYSIS (MFdfa)

## TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer  
pada

Departemen Sistem Informasi  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember

Oleh:

**RISHA ZAHRA ADITYA**

NRP. 05211440000114

Disetujui Tim Penguji: Tanggal Ujian: Juli 2018  
Periode Wisuda: September 2018

Edwin Riksakomara, S.Kom, M.T

(Pembimbing I)

Faizal M., S.Kom, M.Eng, Ph.D

(Pembimbing II)

Wiwik Anggraeni, S.Si, M.Kom

(Penguji I)

Ahmad Mukhlason, S.Kom, M.Sc, Ph.D (Penguji II)



**KLASIFIKASI PROGNOSIS PASIEN ICU  
MENGGUNAKAN ARTIFICIAL NEURAL NETWORK  
(ANN) BERDASARKAN EKSTRAKSI FITUR  
MULTIFRACTAL DETRENDED FLUCTUATION  
ANALYSIS (MFDFA)**

**Nama Mahasiswa : RISHA ZAHRA ADITYA**  
**NRP : 05211440000114**  
**Jurusan : SISTEM INFORMASI**  
**Dosen Pembimbing 1 : Edwin Riksakomara, S.Kom, M.T**  
**Dosen Pembimbing 2 : Faizal Mahananto., S.Kom,  
M.Eng, Ph.d**

**ABSTRAK**

*Intensive Care Unit (ICU) adalah salah satu unit Rumah Sakit yang memiliki peran penting dalam penyembuhan seorang pasien. Memprediksi kondisi pasien setelah keluar dari ICU diperlukan karena akan mempengaruhi perawatan terhadap pasien tersebut. Prioritas pasien yang dapat masuk dan keluar ICU salah satunya juga dipengaruhi oleh prediksi tersebut atau yang biasa disebut dengan prognosis. Prognosis adalah prediksi dari perkembangan penyakit dari pasien, apakah pasien memiliki kemungkinan pulih atau tidak. Prognosis tersebut nantinya juga akan digunakan sebagai pertimbangan atas perawatan dan penanganan yang akan diberikan kepada pasien. Hingga saat ini terdapat beberapa sistem penilaian/skoring prognosis seperti APACHE II, MODS, SOFA, dan SAPS II. Sistem-sistem tersebut akan menghasilkan nilai-nilai yang kemudian akan digambarkan menggunakan formula matematika untuk mendapatkan hasil prognosis pasien. Semakin tinggi nilai yang dihasilkan, maka semakin kecil kemungkinan pasien untuk dapat pulih. Walaupun sistem skoring dapat digunakan dalam mendapatkan hasil prognosis pasien, tetapi terdapat beberapa kekurangan seperti banyaknya variabel dan lamanya waktu yang dibutuhkan.*

*Melihat pentingnya prognosis demi meningkatkan kualitas pelayanan terhadap pasien ICU, maka dibutuhkan sistem prognosis yang lebih efisien.*

*Penelitian ini menggunakan metode Multifractal Detrended Fluctuation Analysis (MFDFA) untuk mengekstraksi fitur yang ada pada sinyal Heart Rate Variability (HRV) pasien ICU. Hasil ekstraksi fitur tersebut nantinya akan diklasifikasi menggunakan metode Artificial Neural Network (ANN) untuk mengetahui perbedaan antara sinyal HRV yang memiliki prognosis yang baik dan buruk pada pasien ICU.*

*Hasil dari penelitian ini diharapkan mampu membantu ICU dalam meningkatkan kualitas dan efisiensi pelayanan terhadap pasien ICU dengan memanfaatkan sinyal HRV sebagai variabel prognosis.*

**Kata kunci:** *Klasifikasi, Multifractal Detrended Fluctuation Analysis, Artificial Neural Network, Prognosis, Heart Rate Variability*

***PROGNOSIS CLASSIFICATION OF ICU PATIENTS  
USING ARTIFICIAL NEURAL NETWORK (ANN) BASED  
ON MULTIFRACTAL DETRENDED FLUCTUATION  
ANALYSIS (MFDFA) FEATURE EXTRACTION***

Name : RISHA ZAHRA ADITYA  
NRP : 05211440000114  
Department : SISTEM INFORMASI  
Supervisor 1 : Edwin Riksakomara, S.Kom, M.T  
Supervisor 2 : Faizal Mahananto., S.Kom, M.Eng,  
Ph.D

**ABSTRACT**

*Intensive Care Unit (ICU) is one out of units in the hospital that has an important role of patients' recovery. Predicting patients' condition after leaving the ICU is needed because it will affect the treatment those patients will received. The priority of patients who enter and leave the ICU is also affected by the prediction or known as prognosis. Prognosis is the prediction of a patient' diseases development, is a patient has the possibility to recover or not. That prognosis will also be used as a consideration of treatments the patient will received. Up until now, there are some prognosis scoring systems such as APACHE II, MODS, SOFA, and SAPS II. Those systems will produce scores that will then be described using mathematical formula to obtain the patient's prognosis result. The higher the score, the smaller the possibility to be recovered. Although scoring systems can be used in obtaining patient's prognosis result, there are some disadvantages of them such as the number of variables and the amount of time required. Seeing the importance of prognosis in order to improve the service quality toward ICU patients, a more efficient prognosis system is needed.*

*This research is using Multifractal Detrended Fluctuation Analysis (MFDFA) method to extract features on ICU patients' Heart Rate Variability (HRV) signal. The features extracted will be then classified using Artificial Neural Network (ANN) method to find out the difference between HRV signal for good prognosis and poor prognosis of ICU patients. The results of this research are expected to help ICU on improving service quality and efficiency toward ICU patients by using HRV signal as prognosis variable.*

**Keywords:** *Classification, Multifractal Detrended Fluctuation Analysis, Artificial Neural Network, Prognosis, Heart Rate Variability*

## KATA PENGANTAR

Alhamdulillahirobbil’alamiin, puji syukur kehadirat Allah SWT karena kasih dan sayang-Nya sehingga penulis dapat menelesaikan penelitian tugas akhir yang berjudul **“Klasifikasi Prognosis Pasien ICU Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Multifractal Detrended Fluctuation Analysis (MFDFA)”**.

Terimakasih penulis ucapan sebesar-besarnya kepada semua pihak yang telah mendukung dan membantu dalam kelancaran pengerjaan penelitian tugas akhir ini. Terimakasih terkhusus, penulis ucapan kepada:

1. Allah SWT yang senantiasa memberi kepercayaan kepada penulis dan selalu menjadi tujuan akhir dalam segala aktivitas yang penulis lakukan.
2. Orangtua penulis yang tidak pernah lelah mendoakan, mendukung, dan mendengarkan keluh kesah penulis tanpa menghakimi.
3. Bapak Edwin Riksakomara dan Bapak Faizal Mahananto selaku dosen pembimbing yang telah dengan sabar meluangkan waktu dan menuntun penulis dalam menyelesaikan penelitian tugas akhir ini.
4. Teman-teman laboratorium ADDI, Alden Wattinema dan Prasetyo Wahyu, yang telah berkontribusi besar dalam pemahaman penulis dalam menggunakan *tools* yang digunakan.
5. Teman-teman laboratorium RDIB, khususnya Fanny Istifadah, Ayusha Qamarasari, Maulita Arumningtyas, dan Redian Galih yang telah menjadi teman seperjuangan dalam menyelesaikan penelitian tugas akhir.
6. Serta pihak-pihak lain yang telah memberi semangat dan membantu dalam penelitian tugas akhir ini

Penelitian tugas akhir ini masih jauh dari sempurna dan penulis bersedia menerima kritik dan saran yang membangun untuk perbaikan di masa mendatang. Semoga penelitian tugas akhir ini dapat bermanfaat kepada pembaca.

Surabaya, Juni 2018

## DAFTAR ISI

ABSTRAK .....	v
ABSTRACT .....	vii
KATA PENGANTAR .....	ix
DAFTAR ISI.....	xi
DAFTAR GAMBAR .....	xv
DAFTAR TABEL.....	xvii
DAFTAR KODE PROGRAM .....	xix
BAB I PENDAHULUAN .....	1
1.1    Latar Belakang .....	1
1.2    Perumusan Masalah.....	5
1.3    Batasan Masalah.....	6
1.4    Tujuan Tugas Akhir.....	6
1.5    Manfaat Kegiatan Tugas Akhir .....	6
1.6    Relevansi .....	7
BAB II TINJAUAN PUSTAKA .....	9
2.1    Penelitian Sebelumnya .....	9
2.2    Dasar Teori .....	10
2.2.1    Klasifikasi.....	10
2.2.2    Prognosis .....	11
2.2.3    Heart Rate Variability (HRV) .....	11
2.2.4    Multifractal Detrended Fluctuation Analysis..	12
2.2.5    Wilcoxon Rank-Sum Test.....	20
BAB III METODOLOGI .....	21
3.1    Diagram Metodologi .....	21
3.2    Uraian Metodologi .....	22

3.2.1	Studi Literatur dan Pengumpulan Data .....	22
3.2.2	Praproses Data .....	22
3.2.3	Ekstraksi Fitur MFDFA .....	22
3.2.4	Klasifikasi ANN .....	23
3.2.5	Penarikan Kesimpulan .....	25
3.2.6	Penyusunan Buku Laporan TA .....	25
BAB IV PERANCANGAN .....		27
4.1	Pengumpulan Data.....	27
4.2	Praproses Data .....	27
4.3	Ekstraksi Fitur MFDFA.....	28
4.3.1	Menghitung Integrasi Time Series .....	28
4.3.2	Menghitung Local RMS .....	28
4.3.3	Menghitung Fungsi Fluktuasi .....	28
4.3.4	Mendapatkan Multifractal Spectrum.....	29
4.3.5	Perhitungan Parameter Input.....	29
4.4	Uji Signifikansi Parameter.....	29
4.5	Permodelan ANN .....	30
4.5.1	Penentuan Parameter ANN .....	30
4.5.2	Pengujian Performa .....	31
BAB V IMPLEMENTASI .....		33
5.1	Praproses Data .....	33
5.2	Ekstraksi Fitur MFDFA.....	35
5.2.1	Menghitung Integrasi Time Series .....	35
5.2.2	Menghitung Local RMS .....	36
5.2.3	Menghitung Fungsi Fluktuasi .....	37
5.2.4	Menghitung Multifractal Spectrum.....	39
5.2.5	Menghitung Parameter Input .....	40

5.3	Uji Coba Model MFDFA .....	41
5.4	Uji Signifikansi Parameter.....	41
5.5	Klasifikasi ANN .....	42
	BAB VI HASIL DAN PEMBAHASAN .....	46
6.1	Hasil Signifikansi MFDFA.....	46
6.2	Hasil Klasifikasi 1 Parameter Input .....	51
6.3	Hasil Klasifikasi ANN.....	55
6.2.1	Hasil Confusion Matrix .....	55
6.2.2	Hasil Akurasi Klasifikasi.....	62
6.2.3	Hasil Uji Performa.....	66
6.4	Kesimpulan Percobaan .....	67
	BAB VII KESIMPULAN DAN SARAN.....	68
7.1	Kesimpulan .....	68
7.2	Saran.....	68
	DAFTAR PUSTAKA .....	70
	BIODATA PENULIS .....	72
	LAMPIRAN A : Hasil Ekstraksi Fitur MFDFA .....	1
	LAMPIRAN B : Hasil Klasifikasi ANN .....	1
	LAMPIRAN C : Hasil Akurasi Klasifikasi ANN .....	1

*(halaman ini sengaja dikosongkan)*

## DAFTAR GAMBAR

Gambar 1.1 Rata-Rata hq .....	4
Gambar 1.2 Rata-Rata Nilai Kelengkungan .....	4
Gambar 2.1 Fungsi Fluktuasi Fq (s) dengan 6 Nilai q.....	14
Gambar 2.2 Generalisasi Hurst Exponent h(q) .....	15
Gambar 2.3 Model Neuron.....	16
Gambar 2.4 Struktur ANN .....	17
Gambar 2.5 Kurva ROC.....	20
Gambar 3.1 Diagram Metodologi.....	21
Gambar 5.1 Plot Random Walk.....	36
Gambar 5.2 Plot Fq vs Scale .....	38
Gambar 5.3 Plot Kemiringan.....	39
Gambar 5.4 Plot Multifractal Spectrum.....	40
Gambar 5.5 Arsitektur ANN .....	43
Gambar 6.1 Multifractal Spectrum Good. Nilai jarak hq = 0.737, nilai kelengkungan = -4.131, rata-rata hq = 1.519, dan standar deviasi hq = 0.275.....	49
Gambar 6.2 Multifractal Spectrum Poor. Nilai jarak hq = 0.517, nilai kelengkungan = -5.244, rata-rata hq = 0.455, dan standar deviasi hq = 0.186.....	49
Gambar 6.3 ROC Model MFDFA 1 .....	52
Gambar 6.4 ROC Model MFDFA 2 .....	53
Gambar 6.5 ROC Model MFDFA 3 .....	54

*(halaman ini sengaja dikosongkan)*

## **DAFTAR TABEL**

Tabel 2.1 Penelitian Sebelumnya .....	9
Tabel 2.2 Istilah dalam Tes Diagnostik .....	18
Tabel 4.1 Parameter ANN.....	30
Tabel 5.1	Annotator..
.....	34
Tabel 5.2 RR Interval.....	34
Tabel 5.3 Model MFDFA.....	41
Tabel 5.4 Implementasi Parameter ANN.....	42
Tabel 6.1	Model
MFDFA.....	46
Tabel 6.2 Hasil Uji Signifikansi 2 Parameter .....	47
Tabel 6.3 Hasil Uji Signifikansi 4 Parameter .....	50
Tabel 6.4 Confusion Matrix Model MFDFA 1.....	52
Tabel 6.5 Confusion Matrix Model MFDFA 2.....	53
Tabel 6.6 Confusion Matrix Model MFDFA 3.....	54
Tabel 6.7 Hasil Klasifikasi Cut-Off Values.....	54
Tabel 6.8 Confusion Matrix 2 Hidden Neuron Model MFDFA 1 .....	55
Tabel 6.9 Confusion Matrix 3 Hidden Neuron Model MFDFA 1 .....	56
Tabel 6.10 Confusion Matrix 4 Hidden Neuron Model MFDFA 1.....	56
Tabel 6.11 Confusion Matrix 5 Hidden Neuron Model MFDFA 1.....	56
Tabel 6.12 Confusion Matrix 6 Hidden Neuron Model MFDFA 1.....	57
Tabel 6.13 Confusion Matrix 2 Hidden Neuron Model MFDFA 2.....	57
Tabel 6.14 Confusion Matrix 3 Hidden Neuron Model MFDFA 2.....	58
Tabel 6.15 Confusion Matrix 4 Hidden Neuron Model MFDFA 2.....	58
Tabel 6.16 Confusion Matrix 5 Hidden Neuron Model MFDFA 2.....	59

Tabel 6.17 Confusion Matrix 6 Hidden Neuron Model MFDFA 2 .....	59
Tabel 6.18 Confusion Matrix 2 Hidden Neuron Model MFDFA 3 .....	60
Tabel 6.19 Confusion Matrix 3 Hidden Neuron Model MFDFA 3 .....	60
Tabel 6.20 Confusion Matrix 4 Hidden Neuron Model MFDFA 3 .....	61
Tabel 6.21 Confusion Matrix 5 Hidden Neuron Model MFDFA 3 .....	61
Tabel 6.22 Confusion Matrix 6 Hidden Neuron Model MFDFA 3 .....	61
Tabel 6.23 Akurasi Klasifikasi Model MFDFA 1 .....	62
Tabel 6.24 Akurasi Klasifikasi Model MFDFA 2 .....	63
Tabel 6.25 Akurasi Klasifikasi Model MFDFA 3 .....	64
Tabel 6.26 Hasil Akurasi Terbaik.....	64
Tabel 6.27 Target vs Hasil Prediksi .....	65
Tabel 6.28 Hasil Uji Performa Cut-Off Terbaik 1 Input .....	66
Tabel 6.29 Hasil Uji Performa ANN Terbaik 4 Input.....	66

## **DAFTAR KODE PROGRAM**

Kode Program 5.1 Kode Program Random Walk .....	36
Kode Program 5.2 Local RMS .....	37
Kode Program 5.3 Fungsi Fluktuasi .....	38
Kode Program 5.4 q-order Exponent.....	39
Kode Program 5.5 Parameter .....	40
Kode Program 5.6 Uji Signifikansi .....	41
Kode Program 5.7 Klasifier ANN .....	44

*(Halaman ini sengaja dikosongkan)*

## **BAB I**

### **PENDAHULUAN**

Pada bagian pendahuluan ini akan dijelaskan tentang latar belakang mengenai permasalahan yang menyebabkan dilakukannya penelitian ini, termasuk rumusan masalah, tujuan, dan manfaat yang akan didapat dari penggeraan penelitian ini.

#### **1.1 Latar Belakang**

*Intensive Care Unit* (ICU) memiliki peran yang sangat penting dalam penyembuhan seorang pasien [1]. Memprediksi kondisi pasien saat keluar dari ICU diperlukan karena akan mempengaruhi perawatan yang akan diterima oleh pasien tersebut. Prioritas pasien yang masuk ke dalam ICU dan keluar dari ICU juga dipengaruhi oleh prediksi tersebut atau yang biasa disebut dengan prognosis [1].

Prognosis adalah prediksi dari perkembangan penyakit pasien apakah pasien tersebut akan pulih atau tidak berdasarkan informasi yang tersedia [2]. Setelah mengetahui prognosis dari pasien, hasil tersebut akan digunakan dalam menentukan rencana yang akan dilakukan kepada pasien sebagai pertimbangan perawatan. Keputusan mengenai rencana penanganan yang akan dilakukan kepada pasien diambil berdasarkan hasil prognosis pasien tersebut.

Terdapat beberapa penilaian/*scoring* prognosis yang dapat dilakukan menggunakan standar parameter objektif hingga saat ini, seperti APACHE II, MODS, SAPS II, dan SOFA [3]. Sistem penilaian/*scoring* prognosis tersebut akan menghasilkan nilai-nilai yang kemudian akan digambarkan menggunakan formula matematika untuk memprediksi kematian dari pasien, dimana semakin tinggi nilai yang dihasilkan maka semakin kecil kemungkinan kesembuhan pasien [1]. Tetapi, sistem *scoring* prognosis ini ternyata dianggap tidak efisien karena banyaknya nilai variabel dan

lama waktu yang dibutuhkan. Untuk dapat melakukan *scoring* prognosis menggunakan APACHE II misalnya, dibutuhkan variabel-variabel seperti usia, status penyakit, keadaan fisiologik, dan status pembedahan (emergensi/elektif, bukan pembedahan) yang dicatat dalam 24 jam pertama sejak pasien masuk ke dalam ICU [1].

Menentukan perawatan yang akan diberikan kepada pasien perlu dilakukan sebanyak tiga kali, yaitu sebelum, saat, dan setelah pelayanan. Hal tersebut dikarenakan oleh hasil prognosis yang dapat berubah berdasarkan penemuan yang didapatkan saat atau setelah dilakukan perawatan [4]. Karena pentingnya prognosis dalam mewujudkan penyembuhan dan pelayanan yang efisien, diperlukan sistem prognosis yang dapat dilakukan secara *real time* demi mendukung efisiensi dan meningkatkan kualitas pelayanan terhadap pasien ICU.

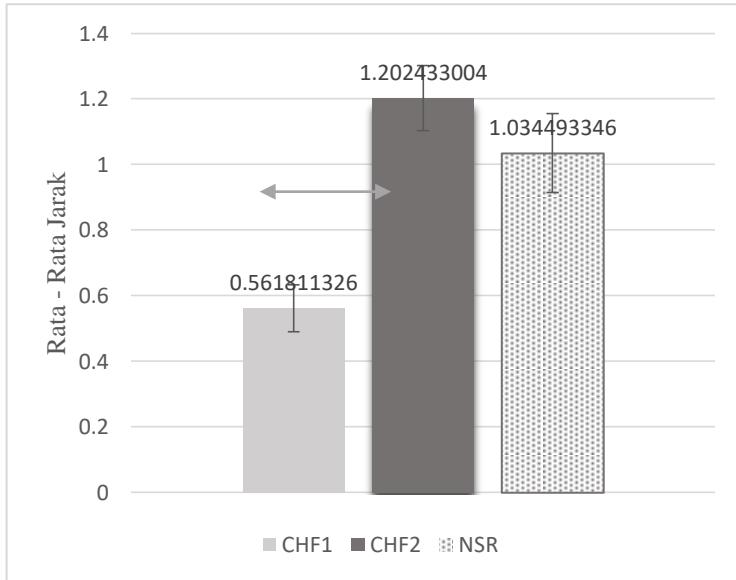
Monitoring terhadap pasien ICU dilakukan secara *real time* terhadap beberapa parameter non-invasif (tidak perlu memasuki tubuh) seperti *electrocardiograph* (ECG), tekanan darah, respirasi, dan suhu tubuh [5]. Karena monitoring dilakukan secara *real time*, data-data kondisi pasien yang digunakan untuk monitoring *real time* tersebut tidak disimpan. Padahal data-data tersebut dapat dianalisa lebih lanjut menjadi *Heart Rate Variability* (HRV) yang merupakan penanda terhadap aktivitas saraf otonom yang mengatur semua kerja organ tubuh tidak sadar seperti jantung, paru-paru, ginjal, lambung, dan pembuluh darah sehingga jika terjadi suatu kerusakan pada organ kinerja saraf otonom juga akan terganggu [6]. Sehingga dapat disimpulkan bahwa kondisi kerusakan organ pasien dapat dilihat dari HRVnya. Untuk mendapatkan sinyal HRV, perlu dilakukan pengukuran interval waktu pada sinyal ECG atau yang biasanya disebut dengan R-R interval [7]. Sinyal HRV adalah sinyal biomedik yang bersifat nonstasioner sehingga tidak cocok untuk diolah menggunakan perhitungan yang konvensional. Di beberapa

kasus, HRV menunjukkan kemunculan *self-similarity pattern/fractal*.

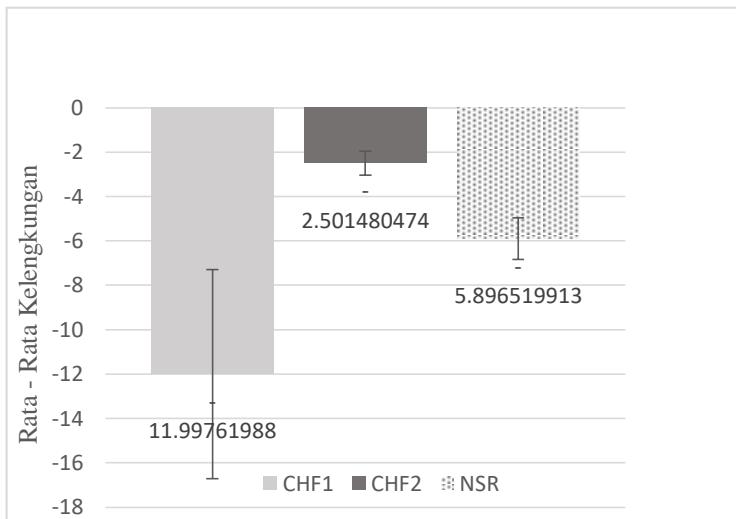
Analisis fraktal sering digunakan dalam memroses sinyal biomedik untuk mendapatkan struktur skala invariant dalam ECG karena sinyal biomedik tidak bisa diolah dengan menggunakan perhitungan yang konvensional. Metode *Detrended Fluctuation Analisis* (DFA) telah dilakukan pada penelitian-penelitian sebelumnya yang ternyata masih belum mampu melihat kemultifraktalan di dalam HRV. Berbagai pengembangan dari analisis telah dikembangkan agar memberikan hasil yang baik saat digunakan pada data *time series* yang nonstasioner, hingga akhirnya dikembangkan *Multifractal Detrended Fluctuation Analysis* (MFDFA) yang dinilai baik untuk digunakan pada data yang bersifat *time series* dan nonstastioner seperti HRV karena mampu melihat ke-*multifractal*-annya [8].

Pentingnya kemunculan *multifractal* pada data dikarenakan oleh adanya hubungan antara hasil ekstraksi fitur MFDFA terhadap kondisi pasien. Pada penelitian sebelumnya yaitu melakukan pendekripsi penyakit kongestif jantung menggunakan sinyal HRV, didapatkan bahwa rata-rata jarak dan rata-rata nilai kelengkungan menunjukkan hasil yang cukup signifikan dalam membedakan kondisi pasien.

Gambar 1.1 dan Gambar 1.2 memperlihatkan perbandingan rata-rata jarak dan kelengkungan dari CHF1 (gagal jantung level 3-4), CHF2 (gagal jantung level 1-2) dan pasien normal [7].



Gambar 1.1 Rata-Rata Jarak hq



Gambar 1.2 Rata-Rata Nilai Kelengkungan

Penelitian ini dilakukan dengan menggunakan metode *Multifractal Detrended Fluctuation Analysis* (MFDFA) dalam mengekstraksi fitur yang ada pada HRVs. Hasil fitur yang akan dihasilkan dari metode MFDFA tadi berupa jarak  $hq$  dan nilai kelengkungan pada *multifractal spectrum* pada masing-masing pasien ICU. Hasil fitur tersebut lalu akan diklasifikasi menggunakan *Artificial Neural Network* (ANN) untuk mendapatkan hasil klasifikasi prognosis dari pasien ICU.

Pemilihan ANN sebagai metode klasifikasi didasarkan oleh penelitian-penelitian yang pernah dilakukan sebelumnya yang memberikan performa baik saat digunakan untuk mengklasifikasikan variabel HRV [7], [9]. ANN juga dinilai sebagai metode yang dapat digunakan pada data yang rumit dan metode ini memiliki kelebihan yaitu memiliki kemampuan belajar dari data dan waktu yang dibutuhkan untuk menganalisa juga relatif cepat dibandingkan metode yang lain [10]. Hasil akurasi klasifikasi dengan metode *cut-off value* adalah sebesar 85.43% dan akurasi klasifikasi dengan model ANN terbaik adalah sebesar 69.35%.

## 1.2 Perumusan Masalah

Berdasarkan penjelasan latar belakang di atas, maka rumusan masalah untuk tugas akhir ini adalah:

1. Bagaimana hasil ekstraksi fitur sinyal HRV pasien ICU menggunakan *Multifractal Detrended Fluctuation Analysis*?
2. Bagaimana model ANN yang digunakan untuk melakukan klasifikasi prognosis pasien ICU?
3. Bagaimana hasil dan akurasi klasifikasi prognosis pasien ICU menggunakan *Artificial Neural Network* dari hasil ekstraksi fitur menggunakan *Multifractal Detrended Fluctuation Analysis* pada sinyal HRV?

### 1.3 Batasan Masalah

Dari permasalahan di atas, maka batasan masalah untuk tugas akhir ini antara lain:

1. Data yang digunakan pada penelitian ini adalah *electrocardiography* (ECG) pasien ICU yang didapatkan dari [www.physionet.org](http://www.physionet.org) yang selanjutnya dikonversi menjadi sinyal HRV.
2. Fitur yang diekstraksi pada penelitian ini menggunakan MFDFA adalah jarak  $h_q$  dan nilai kelengkungan pada *multifractal spectrum*
3. Struktur ANN yang digunakan pada penelitian ini adalah *Backpropagation*
4. Bahasa pemrograman yang digunakan dalam penelitian ini adalah *Python*

### 1.4 Tujuan Tugas Akhir

Dari rumusan masalah yang disebutkan sebelumnya, maka tujuan tugas akhir ini antara lain:

1. Mengetahui hasil ekstraksi fitur sinyal HRV pasien ICU menggunakan *Multifractal Detrended Fluctuation Analysis*
2. Mengetahui model ANN yang baik untuk digunakan dalam melakukan klasifikasi prognosis pasien ICU.
3. Mengetahui hasil dan akurasi klasifikasi prognosis pasien ICU menggunakan *Artificial Neural Network* dari hasil ekstraksi fitur menggunakan *Multifractal Detrended Fluctuation Analysis* pada sinyal HRV.

### 1.5 Manfaat Kegiatan Tugas Akhir

Tugas akhir ini diharapkan dapat memberi manfaat antara lain:

#### **Bagi akademis**

Mengetahui aplikasi permodelan *Artificial Neural Network* untuk mengestimasi prognosis pasien ICU berdasarkan fitur

sinyal HRV pasien yang diekstraksi dengan menggunakan metode *Multifractal Detrended Fluctuation Analysis*.

### **Bagi instansi kesehatan / ahli medis**

Membantu instansi kesehatan dalam melakukan prediksi dan mendapatkan prognosis yang akurat sehingga pelayanan dan penanganan yang diberikan kepada pasien tepat.

### **Bagi universitas**

Menambah referensi dalam penggunaan metode *Artificial Neural Network* untuk mengestimasi fitur sinyal HRV yang diekstraksi dengan menggunakan metode *Multifractal Detrended Fluctuation Analysis*.

## **1.6 Relevansi**

Permasalahan prognosis pada penelitian ini berkaitan dengan kebutuhan unit ICU pada rumah sakit dalam mendapatkan hasil prognosis pasien yang cepat dan akurat. Sistem scoring prognosis yang digunakan hingga saat ini masih tidak efisien karena banyaknya variabel yang dibutuhkan dan waktu yang lama untuk mendapatkan hasil prognosinya. Dengan menggunakan sinyal Heart Rate Variability (HRV) yang memiliki karakteristik timeseries dan nonstationer sebagai variabel dalam melakukan prognosis, proses dalam mendapatkan data dan analisanya menjadi lebih cepat. Metode yang digunakan untuk mengekstraksi sinyal HRV adalah Multifractal Detrended Fluctuation Analysis (MFDFA) karena mampu memunculkan kemultifraktalan sinyal HRV sehingga didapatkan fitur jarak  $hq$  dan nilai kelengkungan yang kemudian dijadikan input pada tahapan klasifikasi menggunakan Artificial Neural Network (ANN). Pemilihan ANN sebagai metode klasifikasi karena penelitian-penelitian sebelumnya menunjukkan hasil yang baik ketika digunakan pada sinyal biomedik.

Relevansi tugas akhir ini terhadap laboratorium Rekayasa Data dan Intelelegensi Bisnis (RDIB) pada Departemen Sistem

Informasi Fakultas Teknologi Informasi dan Komunikasi ITS Surabaya yakni adanya keterkaitan tugas akhir dengan mata Penggalian Data dan Analisis Bisnis, Sistem Pendukung Keputusan, dan Sistem Cerdas mengenai bagaimana penentuan model terbaik untuk melakukan klasifikasi yang akan digunakan dalam menglasifikasikan prognosis pasien ICU berdasarkan sinyal HRV pasien agar tingkat akurasi yang didapatkan tinggi.

## **BAB II**

### **TINJAUAN PUSTAKA**

Pada bagian ini akan dijelaskan mengenai referensi-referensi dan rujukan yang berkaitan dengan penelitian tugas akhir ini.

#### **2.1 Penelitian Sebelumnya**

Sub bagian ini akan memaparkan acuan penelitian-penelitian yang pernah dilakukan sebelumnya yang digunakan oleh penulis dalam melakukan penelitiannya. Tabel 2.1 menjelaskan penelitian yang berkaitan dan pernah dilakukan sebelumnya sebagai acuan utama penulis.

**Tabel 2.1 Penelitian Sebelumnya**

No	Penulis, Tahun	Judul	Keterkaitan dengan Tugas Akhir
1.	Dhimas Yoga Ananta	Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Multifractal Detrended Fluctuation Analysis (MFdfa) pada Variabilitas Denyut Jantung [7]	Penelitian menggunakan metodologi klasifikasi dan ekstraksi yang sama yaitu ANN dan MFdfa.

No	Penulis, Tahun	Judul	Keterkaitan dengan Tugas Akhir
2.	Nurfiana Dwi Astuti	Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan <i>Artificial Neural Network</i> (ANN) Berdasarkan Ekstraksi Fitur <i>Higher-Order Moments Detrended Fluctuation Analysis</i> pada Variabilitas Denyut Jantung [9]	Penelitian menggunakan metode klasifikasi dan variabel yang sama yaitu ANN dengan variabel <i>Heart Rate Variability</i> (HRV)

## 2.2 Dasar Teori

Pada bagian ini akan dijelaskan mengenai referensi yang digunakan sebagai acuan yang berkaitan dengan penelitian tugas akhir ini.

### 2.2.1 Klasifikasi

Klasifikasi adalah proses memprediksi kelas dari data atau mengelompokkan data ke dalam salah satu kelas yang telah ditentukan. Klasifikasi dilakukan dengan cara membangun sebuah model menggunakan *data training* dan label kelasnya kemudian digunakan untuk mengklasifikasikan data baru [11].

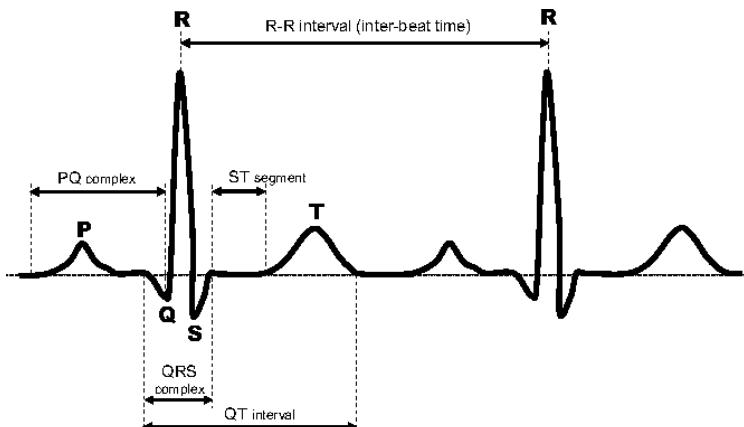
Terdapat dua metode klasifikasi, yaitu *supervised classification* dan *unsupervised classification*. *Supervised classification* adalah metode yang membutuhkan data training untuk menentukan label kelas yang akan digunakan pada proses klasifikasinya, sedangkan *unsupervised classification* tidak membutuhkan label kelas yang ditentukan dan biasanya menggunakan algoritma klustering untuk proses klasifikasinya.

### 2.2.2 Prognosis

Prognosis adalah prediksi dari perkembangan penyakit pasien apakah pasien tersebut akan pulih atau tidak berdasarkan informasi yang tersedia [2]. Setelah mengetahui prognosis dari pasien, hasil tersebut akan digunakan menentukan rencana yang akan dilakukan kepada pasien sebagai pertimbangan perawatan. Terdapat beberapa variabel yang mempengaruhi hasil dari prognosis seperti jenis kelamin, usia, rekam medis, ras, dan lain-lain.

### 2.2.3 Heart Rate Variability (HRV)

*Heart Rate Variability* (HRV) merupakan sebuah cara yang digunakan untuk memantau kondisi dari jantung. HRV adalah keadaan dimana terdapat perbedaan interval waktu antar detak jantung yang terjadi secara terus menerus [12], [13]. Untuk mendapatkan sinyal HRV, perlu dilakukan pengukuran interval waktu pada sinyal *electrocardiography* (ECG) atau yang biasanya disebut dengan R-R interval. Contoh gambar R-R interval dapat dilihat pada Gambar 2.1.



Gambar 2.1 Contoh R-R Interval

### 2.2.4 Multifractal Detrended Fluctuation Analysis

MFdfa merupakan metode ekstraksi fitur pengembangan dari DFA untuk mencari spektrum singulariti  $f(\eta)$  pada data *time series* yang bersifat stasioner dan nonstasioner. Pada umumnya, data *time series* harus memiliki interval waktu intertransaksi [14]. Untuk menghitung spektrum  $f(\eta)$  tersebut dapat dilakukan dengan beberapa tahapan. Tahapan dalam penggunaan metode MFdfa adalah sebagai berikut:

#### Tahap 1

Pada tahapan ini penghitungan integrasi dari *time series* atau disebut dengan *random walk*.

$$y(j) = \sum_{k=1}^j (x_k - \bar{x}), j = 1, \dots, N.$$

#### Tahap 2

Pada tahapan ini perlu untuk membagi *random walk* menjadi  $N_s \equiv (\text{int}(N/s))$ . Karena panjang  $N$  seringkali tidak sesuai dengan kelipatan dari panjang  $s$ , sisanya (lebih pendek dari  $s$ ) bisa dibiarkan. Agar sisa tersebut tidak diabaikan, prosedur yang sama dilakukan lagi dari ujung yang berlawanan (yang dimulai dari nilai  $N$  terakhir dari *random walk*). Hasil dari tahap ini adalah diperolehnya  $2N_s$  segmen. Segmen didapat dan untuk setiap segment kita melakukan minimal square fit dari rangkaian tersebut dan menentukan variansinya [14].

#### Tahap 3

Pada tahapan ini dilakukan perhitungan *local trend* untuk masing-masing segmen dengan menggunakan *least-square fit* lalu menentukan variansinya. Tujuan dari tahapan ini adalah untuk menghilangkan tren/*detrend* pada *random walk* di masing-masing segmen dari panjang  $s$ , secara terpisah. Sehingga perlu dicari variansi

$$F^2(v, s) = \frac{1}{s} \sum_{j=1}^s [y((v-1)s+j) - w_v^n(j)]^2$$

untuk segmen  $v = 1, \dots, Ns$  dan

$$F^2(v, s) = \frac{1}{s} \sum_{j=1}^s [y((N-v-Ns)s+j) - w_v^n(j)]^2$$

untuk segmen  $v = Ns + 1, \dots, 2Ns$ .

dimana  $w_v^n(j)$  adalah *fitting polynomial* di segmen  $v$  [14].

#### Tahap 4

Pada tahapan ini dilakukan pembedaan dua kasus yang berbeda: (i)  $q \neq 0$  dan (ii)  $q \rightarrow 0$ .

##### Case (i):

Untuk kasus ini kita mendefinisikan fungsi fluktuasi:

$$Fq(s) = \left[ \frac{1}{2Ns} \sum_{v=1}^{2Ns} [F^2(v, s)]^{q/2} \right]^{1/q}$$

dimana fungsi fluktuasi  $q$ -dependent ini bergantung ke skala waktu  $s$  untuk nilai  $q$  yang berbeda, karenanya tahapan 2 hingga 4 harus diulang sesuai skala waktu  $s$ .

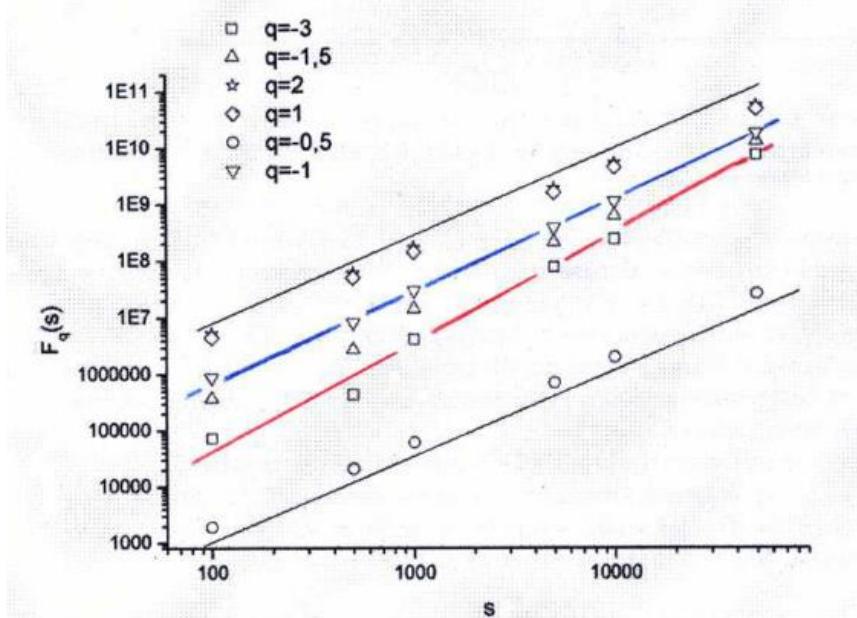
##### Case (ii):

Untuk kasus ini, persamaan sebelumnya diganti menjadi:

$$\begin{aligned} F_{q \rightarrow 0}(s) &\rightarrow F_0(s) \\ &\equiv \exp \left[ \frac{1}{4Ns} \sum_{v=1}^{2Ns} \ln F^2(v, s) \right] \sim s^{h_{(q=0)}} \end{aligned}$$

#### Tahap 5

Pada tahapan ini kita menentukan perilaku penskalaan dari fungsi fluktuasi dengan menganalisa plot dari  $\log Fq(s)$  vs  $s$  untuk nilai  $q$  yang berbeda. Contoh gambar fungsi fluktuasi dapat dilihat pada Gambar 2.2.



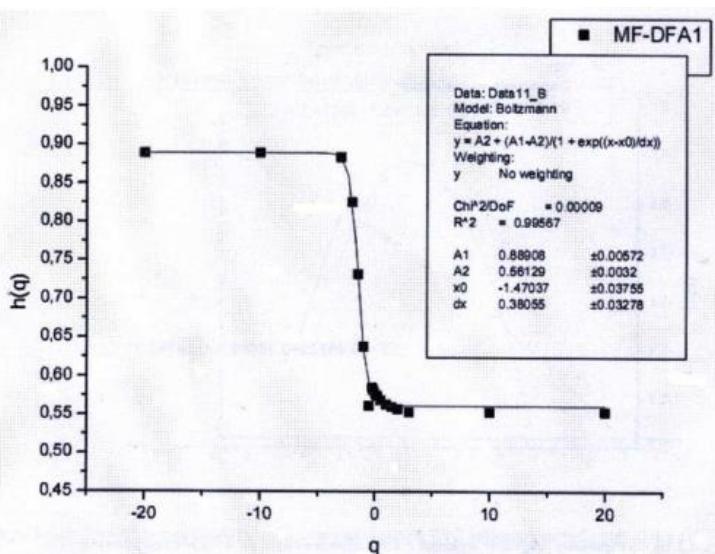
Gambar 2.2 Fungsi Fluktuasi  $F_q(s)$  dengan 6 Nilai  $q$

Diketahui,

$$Fq(s) \approx s^{hq}$$

dimana ( $H_q$ ) adalah  $q$ -order Hurst Exponent yang dapat dilihat pada Gambar 2.3. Eksponen ini mendefinisikan garis lurus seperti pada gambar, sebagai fungsi dari  $q$  [14]. Pada gambar di bawah akan ditampilkan perilaku dari  $h(q)$  vs  $q$ .

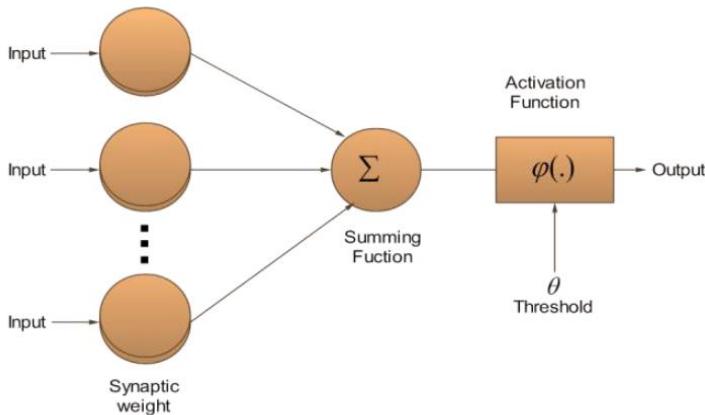
$$\tau(q) = qh(q) - 1$$



Gambar 2.3 Generalisasi Hurst Exponent  $H(q)$  Artificial Neural Networks (ANN)

Jaringan Syaraf Tiruan atau *Artificial Neural Network* (ANN) lahir dari usaha memodelkan otak manusia karena manusia dianggap sebagai sebuah sistem yang paling sempurna [15]. ANN merupakan sebuah model penalaran yang didasarkan pada otak manusia dan juga terdiri dari prosesor yang sederhana dan saling berhubungan yang disebut dengan *neuron* [16].

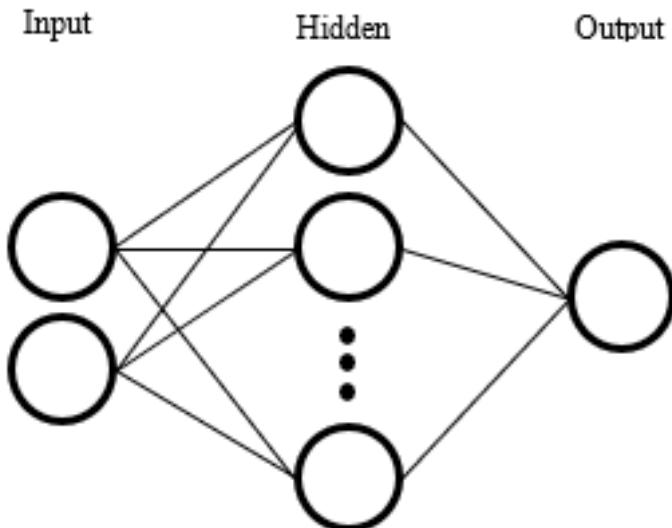
Model ANN terdiri dari fungsi penjumlahah (*summing function*), fungsi aktivasi (*activation function*), dan keluaran (*output*) seperti yang digambarkan pada Gambar 2.4.



**Gambar 2.4 Model Neuron**

ANN bekerja dengan masuknya informasi (*input*) yang kemudian diteruskan ke neuron dengan menggunakan bobot tertentu lalu diproses oleh suatu fungsi yang akan menjumlahkan nilai dari bobot-bobot yang telah digunakan. Hasil penjumlahan dari bobot tersebut kemudian akan dibandingkan dengan nilai ambang (*threshold*) tertentu dengan fungsi aktivasi setiap neuron. Apabila setelah dibandingkan nilai masukan tersebut melewati nilai ambang, maka neuron akan diaktifkan. Neuron yang diaktifkan tersebut akan mengirimkan keluaran ke semua neuron lain yang berhubungan dengannya.

Struktur dari ANN adalah *input layer*, *hidden layer*, dan *output layer* seperti Gambar 2.5.



Gambar 2.5 Struktur ANN

*Input layer* terdiri dari unit-unit *input* dimana unit-unit tersebut menerima pola inputan data dari luar yang merepresentasikan sebuah permasalahan. *Hidden layer* terdiri dari unit-unit tersembunyi dimana keluarannya tidak dapat diamati secara langsung. Dan *output layer* terdiri dari unit-unit *output* yang merupakan solusi dari *input*.

Dalam melakukan penganalisaan terhadap data pada model ANN, data sampel harus dipisahkan menjadi dua, yaitu data *training* dan data *testing*. Data *training* akan digunakan untuk membangun model, sedangkan data *testing* akan digunakan untuk mengukur tingkat akurasi model. Bobot terbesar ada pada data *training*, dimana data ini digunakan dalam pendefinisian parameter model. Sedangkan data *testing* akan digunakan untuk memeriksa keakuratan model peramalah jika diuji pada data diluar data *training*.

Setelah melakukan klasifikasi menggunakan data *training*, selanjutnya akan dilakukan pengujian apakah klasifikasi yang

telah dilakukan sudah baik dan terpercaya atau yang biasa disebut dengan tes diagnostik. Terdapat beberapa atribut yang dapat diukur dalam tes diagnostic terhadap klasifikasi dengan dua kelas ini, yaitu *sensitivity*, *specificity*, dan *accuracy*. *Sensitivity* digunakan untuk mengevaluasi bagaimana suatu metode dalam mendeteksi bahwa seseorang positif berpenyakit. *Specificity* digunakan untuk mengestimasi bagaimana pasien yang sehat memiliki hasil tes yang negatif [17], [18]. Istilah yang digunakan dalam Confusion Matrix dapat dilihat pada Tabel 2.2.

**Tabel 2.2 Istilah dalam Tes Diagnostik**

Hasil Tes Diagnostik	Kondisi		
	Positive	Negative	Raw Total
Positive	TP ( <i>True Positive</i> )	FP ( <i>False Positive</i> )	TP + FP (Jumlah total subyek dengan hasil tes positif)
Negative	FN ( <i>False Negative</i> )	TN ( <i>True Negative</i> )	FN + TN (Jumlah total subyek dengan hasil tes negatif)
Column Total	TP + FN (Jumlah total subyek dengan kondisi yang telah diberikan)	FP + TN (Jumlah total subyek tanpa kondisi yang telah diberikan)	N = TP + TN + FP + FN (Jumlah total subyek yang digunakan)

### ***Accuracy***

$$\begin{aligned}
 &= \frac{(\text{True Negative} + \text{True Positive})}{(\text{True Positive} + \text{True Negative} + \text{False Negative} + \text{False Positive})} \\
 &= \frac{(\text{Jumlah prediksi benar})}{(\text{Jumlah data})}
 \end{aligned}$$

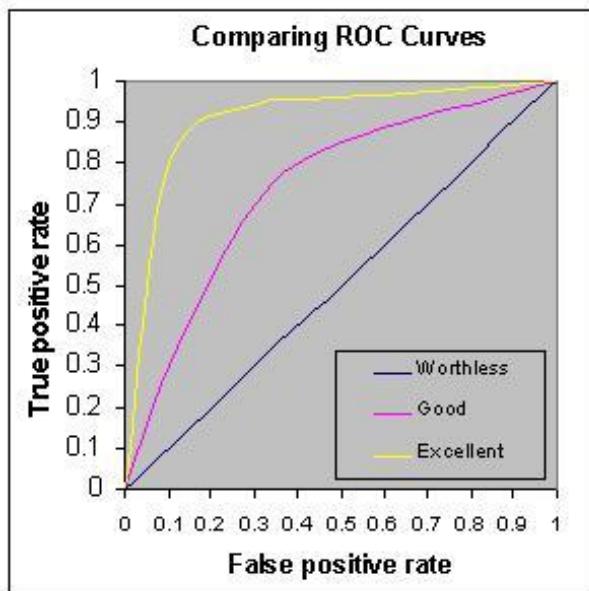
### *Sensitivity*

$$\begin{aligned}
 &= \frac{\text{True Positive}}{(\text{True Positive} + \text{False Negative})} \\
 &= \frac{(\text{Jumlah data positif diprediksi dengan benar})}{(\text{Jumlah prediksi benar})}
 \end{aligned}$$

### *Specificity*

$$\begin{aligned}
 &= \frac{\text{True Negative}}{(\text{True Negative} + \text{False Positive})} \\
 &= \frac{(\text{Jumlah data negatif diprediksi dengan salah})}{(\text{Jumlah prediksi salah})}
 \end{aligned}$$

Hasil pengukuran *specificity* dan *sensitivity* tadi kemudian akan digambarkan kedalam kurva *Receiver-Operating Characteristic* (ROC) yang berguna untuk menguji performa metode klasifikasi yang kita gunakan tadi. Sedangkan *accuracy* akan digunakan untuk mengukur seberapa benar pengujian yang dilakukan dan memberikan parameter untuk membandingkan hasil sebuah metode dengan metode lainnya. Kurva ROC dapat dilihat pada Gambar 2.6.



Gambar 2.6 Kurva ROC

### 2.2.5 Wilcoxon Rank-Sum Test

*Wilcoxon Rank-Sum Test* atau bisa juga disebut sebagai *Mann Whitney U Test* adalah uji nonparametrik yang dilakukan untuk menghitung signifikansi antara dua kelas data. Uji ini dilakukan sebagai alternatif *two-sample t-test* apabila data tidak memenuhi kriteria yaitu data harus terdistribusi dengan normal. Meskipun begitu, uji ini masih tetap dapat digunakan pada data dengan bentuk distribusi apapun, baik normal ataupun tidak. Uji ini juga tidak sesensitif *two-sample t-test* pada *outliers* [19].

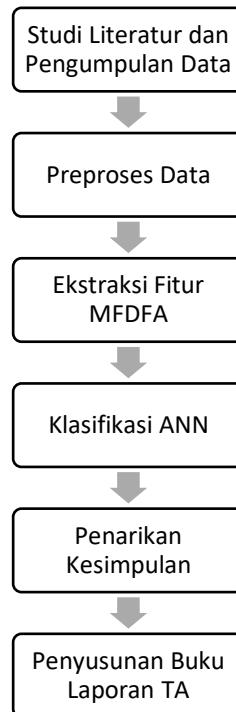
## BAB III

### METODOLOGI

Pada bagian ini akan dijelaskan mengenai metode penggerjaan tugas akhir yang dilakukan penulis.

#### 3.1 Diagram Metodologi

Metodologi ini akan mensistematiskan langkah-langkah penggerjaan tugas akhir. Diagram metodologi dapat dilihat pada Gambar 3.1.



Gambar 3.1 Diagram Metodologi

### **3.2 Uraian Metodologi**

Pada bagian ini akan diuraikan aktivitas yang dilakukan dalam pelaksanaan metodologi.

#### **3.2.1 Studi Literatur dan Pengumpulan Data**

Pada tahapan ini dilakukan studi literatur dengan cara mempelajari penelitian-penelitian terkait yang telah dilakukan sebelumnya mengenai hal-hal yang masih kurang dipahami dan yang dapat dijadikan referensi dalam penggunaan metodologi yang digunakan dalam penelitian, yaitu *Artificial Neural Network* dan *Multifractal Detrended Fluctuation Analysis*. Pengumpulan data yang akan digunakan pada penelitian ini dilakukan dengan mengunduh data yang tersedia dari website *physionet.org*.

#### **3.2.2 Praproses Data**

Pada tahapan ini dilakukan praproses data *electrocardiography* (ECG) yang didapatkan dari website *physionet.org* dari sinyal jantung pasien ICU yang kemudian dikonversi menjadi *Heart Rate Variability* (HRV) dengan cara menghitung jarak antar gelombang R-R pada sinyal ECG tersebut. Praproses data ini diawali dengan melakukan penulisan *syntax* ke dalam *command line* Cygwin untuk mengonversi sinyal ECG yang tersedia di website *physionet.org*. Kemudian dengan menggunakan kode program yang telah dibuat, data ECG yang akan dikonversi dijadikan inputan sehingga dihasilkan data R-R interval yang dapat digunakan sebagai input pada tahapan selanjutnya.

#### **3.2.3 Ekstraksi Fitur MFDFA**

Ekstraksi fitur MFDFA akan dilakukan pada sinyal HRV yang telah didapatkan dari tahapan sebelumnya. Setelah dilakukan ekstraksi fitur, maka akan didapatkan keluaran berupa jarak *hq* dan nilai kelengkungan pada *multifractal spectrum* pada masing-masing pasien ICU yang memiliki prognosis baik dan buruk. Nilai-nilai yang telah didapatkan tersebut kemudian akan diuji signifikansi datanya.

### 3.2.4 Klasifikasi ANN

Data yang telah lulus hasil uji signifikansi yang telah didapatkan dari tahapan sebelumnya kemudian akan diklasifikasi menggunakan *Artificial Neural Network* (ANN).

#### Permodelan Data

Tahapan pertama yang dilakukan untuk melakukan klasifikasi adalah membangun *classifier* yang akan digunakan. Pada penelitian ini akan digunakan *classifier* ANN *Backpropagation*. Kemudian akan dilakukan tahapan-tahapan untuk membangun model ANN yang akan digunakan seperti berikut:

- a) Permilihan variabel *input* dan *output*
- b) Pembagian data sampel
- c) Pembentukan model ANN

Penjelasan lebih dalam dari tahapan-tahapan di atas akan dijelaskan di bawah ini.

##### a) Pemilihan Variabel *Input* dan *Output*

Pada model ANN, diperlukan variabel-variabel dependen dan independen yang disebut sebagai variabel *input* dan variabel *output*. Variabel *input* pada penelitian ini adalah hasil ekstraksi fitur yaitu nilai jarak hq dan nilai kelengkungan yang telah lulus uji signifikansi, sedangkan variabel *output* pada penelitian ini adalah hasil klasifikasi prognosis pasien ICU.

##### b) Pembagian Data Sampel

Dalam melakukan penganalisaan terhadap data pada model ANN, data sampel harus dipisahkan menjadi dua, yaitu data *training* dan data *testing*. Data *training* akan digunakan untuk membangun model, sedangkan data *testing* akan digunakan untuk mengukur tingkat akurasi model. Sebanyak 70% dari sampel data akan digunakan

sebagai data *training* dan 30% sisanya akan digunakan sebagai data *testing*.

c) Pembentukan model ANN

Pada tahapan ini akan dibentuk model ANN yang akan digunakan dalam melakukan klasifikasi. Model ANN dibangun berdasarkan arsitektur ANN dimana neuron *hidden layer* akan didapatkan dengan melakukan *trial* dan *error*. Fungsi aktivasi yang akan digunakan adalah sigmoid biner karena inputan merupakan interval antara 0 – 1.

***Pengujian Data Training***

Setelah membangun model ANN, maka selanjutnya dilakukan pengujian model menggunakan data *training*. Data *training* yang digunakan adalah 70% dari keseluruhan jumlah data pasien ICU yang digunakan pada penelitian ini.

***Pengujian Data Testing***

Setelah melakukan pengujian model ANN terdapat data *training*, selanjutnya dilakukan pengujian model terhadap data *testing*, yaitu 30% dari sisa data pasien ICU yang digunakan pada penelitian ini. Dari pengujian beberapa model yang dilakukan, akan dipilih model terbaik berdasarkan nilai error yang paling kecil saat diuji pada data *testing*.

***Pengujian Performa***

Tahap ini merupakan tahapan akhir dari penggerjaan tugas akhir ini dimana proses pengujian keakuratan klasifikasi dari model ANN yang telah ditentukan dilakukan. Untuk menghitung keakuratan klasifikasi dapat dihitung dengan menggunakan *Confusion Matrix* dan ROC.

### **3.2.5 Penarikan Kesimpulan**

Pada tahapan ini dilakukan penarikan kesimpulan dari penelitian yang telah dilakukan, yaitu penerapan metode *Multifractal Detrended Fluctuation Analysis* (MFDA) pada sinyal HRV yang digunakan untuk mengekstraksi fitur dan penerapan metode *Artificial Neural Network* (ANN) yang digunakan untuk mengklasifikasi sinyal *Heart Rate Variability* (HRV) untuk mengestimasi prognosis pasien ICU.

### **3.2.6 Penyusunan Buku Laporan TA**

Setelah penarikan kesimpulan, tahapan terakhir dalam penelitian ini adalah pembuatan dokumentasi penelitian dalam bentuk buku laporan tugas akhir. Di dalam laporan tugas akhir akan berisikan:

a. BAB I Pendahuluan

Pada bab ini dijelaskan tentang latar belakang, sekilas keadaan organisasi, permasalahan yang menyebabkan adanya penelitian ini, rumusan permasalahan, tujuan, dan manfaat yang akan didapat dari penggerjaan penelitian ini

b. BAB II Tinjauan Pustaka

Pada bagian ini dijelaskan mengenai referensi-referensi dan rujukan yang berkaitan dengan penelitian ini

c. BAB III Metodologi

Pada bab ini dijelaskan mengenai metode pengerjaan tugas akhir yang dilakukan

d. BAB IV Perancangan

Pada bab ini akan dijelaskan mengenai perancangan pelaksanaan metodologi penelitian yang akan dilakukan

e. BAB V Implementasi

Pada bab ini akan dijelaskan mengenai proses pelaksanaan metodologi penelitian yang telah dirancang

f. BAB VI Hasil dan Pembahasan

Pada bab ini akan dibahas mengenai hasil dan analisa dari implementasi metode dalam penelitian ini

g. BAB VII Kesimpulan dan Saran

Bab ini akan berisikan kesimpulan dari seluruh aktivitas dan hasil dari penelitian ini serta saran-saran yang dapat diberikan untuk pengembangan penelitian selanjutnya

## **BAB IV**

### **PERANCANGAN**

Pada bagian ini akan dijelaskan mengenai rancangan penggerjaan penelitian ini meliputi pemilihan obyek penelitian.

#### **4.1 Pengumpulan Data**

Data yang akan digunakan pada penelitian ini adalah data sinyal ECG pasien ICU yang didapatkan dari physionet.org. Sinyal ECG pasien ICU terdiri dari 2 file yaitu *signal files* yang tersedia dalam bentuk .dat (*digitalized signal*) dan *header files* yang tersedia dalam bentuk .hea (*header*). *Signal files* adalah adalah file biner yang berisikan sampel dari sinyal digital. File ini berisikan gelombang yang hanya bisa dibaca dengan adanya *header*. *Header files* adalah file teks pendek yang menjelaskan isi dari *signal file*.

#### **4.2 Praproses Data**

Dari total sinyal ECG pasien ICU, dipilih pasien yang berada di MICU (*Medical Intensive Care Unit*) atau instalasi bagi pasien dewasa yang mengancam jiwa tetapi tidak membutuhkan pembedahan dengan segera [20]. Dari pasien yang berasal dari instalasi MICU, dipilih lagi pasien yang memiliki diagnosis SEPSIS atau keadaan dimana terdapat banyak bakteri di dalam darah dan terjadi peradangan di dalam tubuh sehingga menyebabkan gangguan pada organ tubuh.

Setelah didapatkan data yang memenuhi kriteria, data akan dibagi menjadi dua kelas, yaitu prognosis *good* dan prognosis *poor*. Prognosis *good* adalah pasien yang tidak meninggal di ICU dan prognosis *poor* adalah pasien yang meninggal di ICU. Pembagian kelas ini dibutuhkan untuk dijadikan target output saat pengklasifikasian data dilakukan.

Pada tahapan praproses data, dilakukan pengolahan data yang didapatkan sehingga data dapat digunakan. Data yang didapatkan masih dalam bentuk sinyal ECG (.dat dan .hea), dimana ekstensi .dat adalah data *digitalized signal* dari sinyal ECG yang disimpan dalam bentuk biner dan ekstensi .hea adalah data header yang digunakan untuk membaca file berekstensi .dat, sehingga harus dikonversi menjadi RR interval dari sinyal ECG tersebut.

### 4.3 Ekstraksi Fitur MFDFA

Setelah dilakukan praproses data, data akan digunakan untuk tahapan selanjutnya, yaitu ekstraksi fitur dengan menggunakan MFDFA. Terdapat beberapa tahapan pada MFDFA sehingga akhirnya dapat dilakukan perhitungan parameter yang akan digunakan sebagai input klasifikasi ANN.

#### 4.3.1 Menghitung Integrasi Time Series

Pada tahapan ini dilakukan penghitungan integrasi dari *time series* dengan cara mengurangi masing-masing nilai pada data *time series* dengan rata-rata *time series* sehingga didapatkan *random walk*.

#### 4.3.2 Menghitung Local RMS

Setelah didapatkan *random walk*, dilakukan perhitungan *local RMS* (*Root Mean Square*) dari *random walk* yang telah didapatkan. Perhitungan RMS ini dilakukan dengan melakukan *fitting polynomial* pada *random walk* yang telah dibagi kebeberapa segmen/bagian berdasarkan *scales* yang digunakan.

#### 4.3.3 Menghitung Fungsi Fluktuasi

Hasil *local RMS* kemudian akan digunakan untuk mendapatkan  $F_q$  (fungsi fluktuasi). Hasil fungsi fluktuasi ini dipengaruhi oleh *scales* pada beberapa nilai  $q$  berbeda yang digunakan. Karena itu, proses perhitungan fungsi fluktuasi

dilakukan beberapa kali sesuai dengan *scales* yang digunakan. Hasil *fitting polynomial* antara log fungsi fluktuasi dengan log *local RMS* adalah *q-order Hurst exponent* ( $H_q$ ).

#### **4.3.4 Mendapatkan Multifractal Spectrum**

Untuk mendapatkan *multifractal spectrum*, perlu dilakukan pengonversian  $H_q$  menjadi *q-order mass exponent* ( $t_q$ ) lalu dikonversi menjadi *q-order singularity exponent* ( $h_q$ ) dan *q-order singularity dimension* ( $D_q$ ). Plot antara  $h_q$  vs  $D_q$  disebut sebagai *multifractal spectrum*.

#### **4.3.5 Perhitungan Parameter Input**

Tahapan terakhir pada ekstraksi fitur ini adalah melakukan perhitungan parameter input yaitu jarak  $h_q$  (*q-order singularity exponent*) dan nilai kelengkungan. Jarak  $h_q$  adalah jarak antara nilai tertinggi dan terendah dari *q-order singularity exponent* yang merupakan hasil *fitting polynomial* antara log fungsi fluktuasi dengan log *local RMS* (*Root Mean Square*).

Sedangkan nilai kelengkungan didapatkan dengan melakukan *fitting* kurva polinomial dengan derajat polinomial 2, yaitu parabola, pada *multifractal spectrum*. *Multifractal spectrum* akan didapatkan dengan melakukan plot antara  $h_q$  vs  $D_q$  (*q-order singularity dimension*). *Fitting* kurva tersebut akan menghasilkan tiga nilai yaitu  $a$ ,  $b$ , dan  $c$  yang merupakan nilai dari persamaan  $ax^2+bx+c$ . Karena yang akan digunakan adalah nilai kelengkungan/*slope*, maka nilai yang diambil hanya nilai  $a$  saja.

### **4.4 Uji Signifikansi Parameter**

Setelah didapatkan jarak  $h_q$  dan nilai kelengkungan lalu dilakukan uji signifikansi. Uji signifikansi akan dilakukan dengan *Wilcoxon Ranksum Test*. Data yang digunakan dibagi menjadi dua yaitu pasien dengan prognosis *good* dan *poor*. Pasien dengan prognosis *good* adalah pasien yang tidak

meninggal di ICU sedangkan pasien dengan prognosis *poor* adalah pasien yang meninggal di ICU. Jarak *hq* dan nilai kelengkungan dari semua pasien akan diuji signifikasinya dan fitur tersebut dinilai lulus uji apabila *p-value* yang dihasilkan  $\leq 0.05$ . Uji Signifikansi ini akan dilakukan dengan menggunakan bahasa pemrograman *Python* pada semua model MF DFA yang telah ditentukan.

## 4.5 Permodelan ANN

Fitur yang telah lulus uji signifikansi kemudian akan menjadi input pada tahapan klasifikasi dengan menggunakan metode ANN *Backpropagation*.

### 4.5.1 Penentuan Parameter ANN

Pada tahapan permodelan ANN dibutuhkan *input layer*, *hidden layer*, dan *output layer* sebagai parameter dari arsitektur ANN. Input *layer* akan memiliki dua neuron yaitu jarak *hq* dan nilai kelengkungan. Jumlah lapisan *hidden layer* yang akan digunakan adalah satu lapisan dengan fungsi aktivasi sigmoid, sedangkan untuk jumlah *neuron* pada *hidden layer* akan ditentukan dengan melakukan *trial & error*. *Output layer* akan memiliki satu neuron yaitu hasil prognosis *good* atau *poor*. Parameter yang akan digunakan dalam permodelan ANN dapat dilihat pada Tabel 4.1.

**Tabel 4.1 Parameter ANN**

Parameter	Jumlah Neuron	Deskripsi
Input Layer	2 neuron	Jarak <i>hq</i> dan nilai kelengkungan
Hidden Layer	<i>Trial &amp; Error</i>	2-6 neuron
Output Layer	1 neuron	Prognosis <i>good</i> atau <i>poor</i>
Epoch	3000	<i>Fix</i>

#### 4.5.2 Pengujian Performa

Model ANN yang telah didapatkan diuji performanya untuk menetukan apakah model tersebut baik atau tidak. Performa dari model akan dinilai menggunakan *Confusion Matrix* hingga didapatkan *accuracy*, *specificity* dan *sensitivity*, dan, ROCnya.

*Accuracy* digunakan untuk mengukur seberapa benar pengujian yang dilakukan dan memberikan parameter untuk membandingkan hasil sebuah model dengan model lainnya. *Sensitivity* digunakan untuk mengevaluasi bagaimana suatu metode dalam mendeteksi bahwa seseorang yang memiliki prognosis *good* dan akan *survive* diprediksi dengan benar bahwa orang tersebut diprediksi memiliki prognosis *good* dan akan *survive*. *Specificity* digunakan untuk mengevaluasi bagaimana suatu metode dalam mendeteksi bahwa seseorang yang memiliki prognosis *poor* dan tidak akan *survive*/meninggal diprediksi dengan salah bahwa orang tersebut memiliki prognosis *good* dan akan *survive*.

*(halaman ini sengaja dikosongkan)*

## **BAB V**

## **IMPLEMENTASI**

Pada bab ini akan dibahas mengenai pengimplementasian dari bab perencanaan penelitian tugas akhir ini.

### **5.1 Praproses Data**

Dari total sinyal ECG pasien ICU, dipilih pasien yang berada di MICU (*Medical Intensive Care Unit*) atau instalasi bagi pasien dewasa yang mengancam jiwa tetapi tidak membutuhkan pembedahan dengan segera [20]. Dari pasien yang berasal dari instalasi MICU, dipilih lagi pasien yang memiliki diagnosis SEPSIS atau keadaan dimana terdapat banyak bakteri di dalam darah dan terjadi peradangan di dalam tubuh sehingga menyebabkan gangguan pada organ tubuh.

Dari total data ECG pasien ICU yang tersedia di physionet.org yaitu 10.828 pasien, tersisa 206 pasien ICU yang datanya tersedia dan memenuhi syarat dan informasi mengenai kondisi pasien saat keluar dari ICU tersedia.

Dari 206 pasien, dilakukan pembagian data menjadi 2 kelas yaitu pasien dengan prognosis *good* dan pasien dengan prognosis *poor*. Prognosis *good* adalah pasien yang keluar dari ICU dalam keadaan hidup dan prognosis *poor* adalah pasien yang keluar dari ICU dalam keadaan tidak hidup/meninggal. Pembagian kelas ini dibutuhkan untuk dijadikan target output saat pengklasifikasian data dilakukan. Dari 206 pasien, terdapat 72 pasien dengan prognosis *poor* dan 134 pasien dengan prognosis *good*.

Data sinyal ECG (.dat dan .hea) masing-masing pasien yang didapatkan akan dikonversi menjadi RR interval dengan menggunakan Cygwin. Untuk dapat mengubah sinyal ECG menjadi RR interval, sebelumnya sinyal ECG harus diubah menjadi annotator terlebih dahulu. *Syntax* yang digunakan

pada Cygwin untuk mengonversi sinyal ECG menjadi *annotator* adalah

```
gqrs -r [records name] -s II.
```

Sedangkan *syntax* yang digunakan pada Cygwin untuk membaca data *annotator* ini adalah

```
rdann -a qrs -r [record name].
```

Hasil konversi sinyal digital ECG menjadi *annotator* dapat pada Tabel 5.1.

**Tabel 5.1 Annotator**

06:21:09.176	26/07/2188	225022	N	0	0	10
06:21:09.744	26/07/2188	225093	N	0	0	10
06:21:10.312	26/07/2188	225164	N	0	0	10
06:21:12.000	26/07/2188	225375	N	0	0	10
06:21:12.616	26/07/2188	225452	N	0	0	10

Setelah *annotator* didapatkan, barulah dilakukan pengonversian menjadi RR interval dengan *syntax*

```
ann2rr -r [input] -a qrs -p N -i s3 -V s3  
-w >output.rr.
```

RR interval merupakan sinyal CSV dengan tiga nilai yaitu detik keluar sinyal, nilai RR interval, dan status sinyal RR. Hasil konversi *annotator* menjadi RR Interval dapat dilihat pada Tabel 5.2

**Tabel 5.2 RR Interval**

Detik ke-	Jarak RR Interval	Status
0.000	2.728	N
2.728	0.544	N
3.272	0.768	N

4.040	0.768	N
4.808	0.776	N
5.584	0.768	N
6.352	0.776	N
7.128	0.768	N
7.896	0.768	N
8.664	0.768	N

Dari tabel di atas dapat diketahui bahwa kolom pertama adalah detik dimulainya RR Interval, kolom ke dua adalah lama detik RR Interval, kolom ke tiga adalah status sinyal ECG. Semua sinyal ECG yang detak jantungnya terdeteksi akan berlabel normal atau N. Data yang akan digunakan pada penelitian ini adalah kolom kedua, yaitu lama detik RR Interval.

## 5.2 Ekstraksi Fitur MFDFA

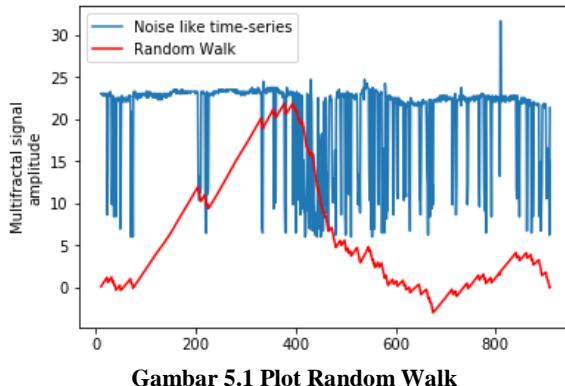
Dari RR interval yang telah didapatkan, dilakukan pemilihan data yang akan digunakan untuk ekstraksi fitur dengan MFDFA. Data yang akan digunakan adalah sebanyak 900 index RR interval per pasien. Karena data di awal *time series* banyak yang memiliki *noise* maka data yang digunakan adalah data dengan index 10 hingga 909.

### 5.2.1 Menghitung Integrasi Time Series

Tahapan awal dalam melakukan ekstraksi fitur menggunakan MFDFA adalah dengan mengubah *noise like time series* menjadi *random walk time series*. *Random walk time series* didapatkan dengan mengurangi tiap nilai pada *time series* dengan rata-rata dari *time series* tersebut. Dalam *Python*, kode program yang digunakan untuk mendapatkan *random walk* adalah seperti Kode Program 5.1. Dan jika di-*plot* maka akan menghasilkan gambar seperti Gambar 5.1.

```
def rwalk(X, axis=-1):
    shp = list(X.shape)
    shp[axis] = 1
    return np.cumsum(X-X.mean(axis).reshape(*shp),axis)

RW = rwalk(input.ravel())
```

**Kode Program 5.1 Kode Program Random Walk****Gambar 5.1 Plot Random Walk**

### 5.2.2 Menghitung Local RMS

Setelah didapatkan *random walk*, dilakukan perhitungan *Local RMS* (*Root Mean Square*) dari *random walk* yang telah didapatkan. Perhitungan RMS ini dilakukan dengan melakukan *fitting polynomial* pada *random walk* yang telah dibagi kebeberapa segmen/bagian berdasarkan *scales* yang digunakan. *Scales* yang digunakan pada penelitian ini adalah [16,32,64,128,256,512]. Penggunaan *scales* didapatkan dari antilog(2) dari log2(20) hingga log2(900) yang dibulatkan ke bawah yaitu 4 dan 9. Sehingga *scales* merupakan antilog(2) dari 4,5,6,7,8,dan 9. Nilai 20 didapatkan karena syarat penggunaan nilai *scales* dalam MFdfa adalah di atas 10, sehingga antilog(2) 4 digunakan karena nilainya lebih besar dari 10 dan paling mendekati 10, sedangkan nilai 900

didapatkan dari panjang data yang digunakan. Perhitungan *local RMS* dapat dilakukan seperti pada Kode Program 5.2.

```
def compRMS(X,scales,m=1,verbose=False):
    t = np.arange(X.shape[0])
    step = scales[0]
    i0s = np.arange(0,X.shape[0],step)
    out = p.zeros((len(scales),i0s.shape[0]),'f8')
    for si,scale in enumerate(scales):
        if verbose: print ('.'),
        s2 = scale//2
        for j,i0 in enumerate(i0s-s2):
            i1 = i0 + scale
            if i0 < 0 or i1 >= X.shape[0]:
                out[si,j] = nan
                continue
            t0 = t[i0:i1]
            C = np.polyfit(t0,X[i0:i1],m)
            fit = np.polyval(C,t0)
            out[si,j] = np.sqrt(((X[i0:i1]-fit)**2).mean())
    return out

RMS = compRMS(RW,scales,1)
```

**Kode Program 5.2 Local RMS**

### 5.2.3 Menghitung Fungsi Fluktuasi

Hasil RMS kemudian akan digunakan untuk mendapatkan fungsi fluktuasi ( $F_q$ ). Hasil fungsi fluktuasi ini dipengaruhi oleh *scales* pada beberapa nilai  $q$  berbeda yang digunakan. Karena itu, proses menghitung fungsi fluktuasi dilakukan beberapa kali sesuai dengan  $q$  yang digunakan. Kode program yang digunakan untuk mendapatkan fungsi fluktuasi adalah seperti pada Kode Program 5.3. Hasil *fitting polynomial* antara log fungsi fluktuasi dengan log *local RMS* adalah *q-order Hurst exponent* ( $H_q$ ).

```

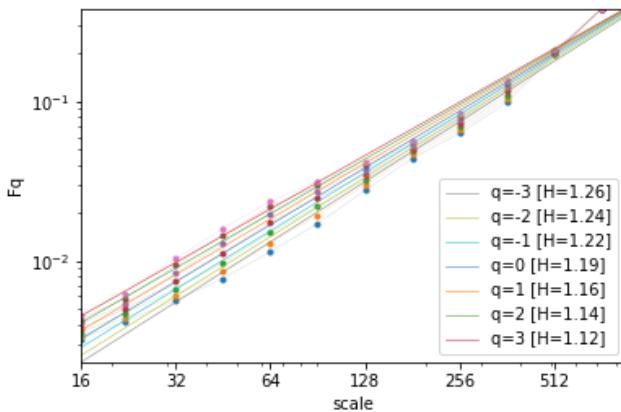
def compFq(rms,qs):
    out = np.zeros((rms.shape[0],len(qs)),'f8')
    mRMS = ma.array(rms,mask=np.isnan(rms))
    for qi in range(len(qs)):
        p = qs[qi]
        out[:,qi] = (mRMS**p).mean(1)**(1.0/p)
    out[:,qs==0] = np.exp(0.5*(np.log
        (mRMS**2.0)).mean(1))[:,None]
    return out

Fq = compFq(RMS,qs)

```

### Kode Program 5.3 Fungsi Fluktuasi

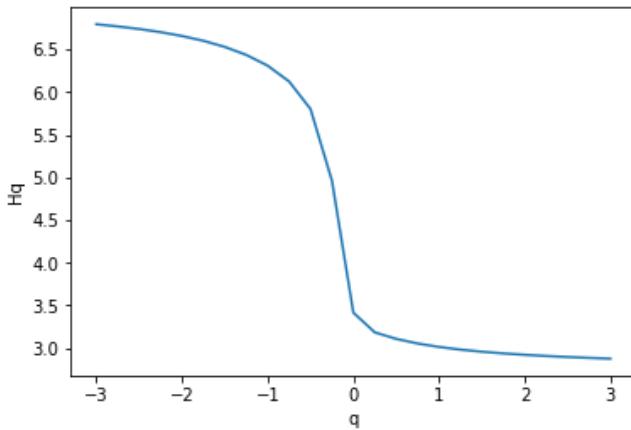
Data yang bersifat multifraktal akan menunjukkan adanya pengaruh  $q$  terhadap  $H_q$ , sedangkan pada data yang bersifat monofraktal akan menunjukkan nilai  $H_q$  yang konstan. Nilai  $slope$   $H_q$  pada  $F_q$  dengan  $q < 0$  vs  $scales$  akan menunjukkan angka yang lebih besar dari  $slope$  untuk  $F_q$  dengan  $q > 0$ . Hasil plot antara  $F_q$  dengan  $scale$  dapat dilihat pada Gambar 5.2.



Gambar 5.2 Plot  $F_q$  vs Scale

### 5.2.4 Menghitung Multifractal Spectrum

Nilai  $H_q$  yang telah didapatkan dari masing-masing  $q$  kemudian diplot untuk dilihat kemiringannya. Apabila nilai  $H_q$  untuk  $q < 0$  lebih besar dari  $H_q$  untuk  $q > 0$  seperti pada Gambar 5.3, maka data memiliki sifat multifraktal.



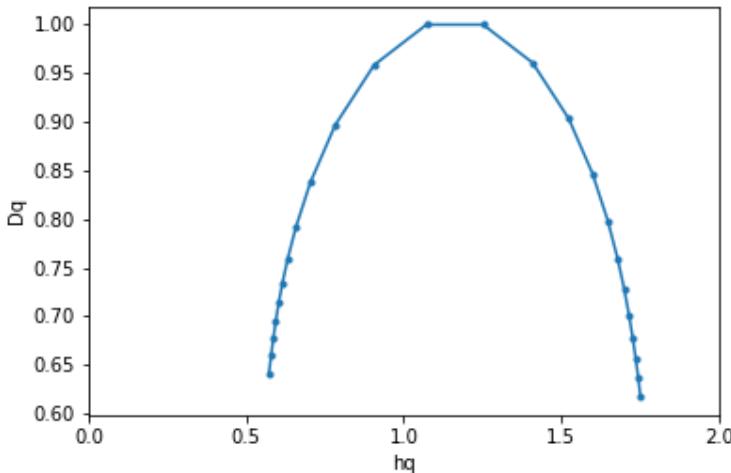
Gambar 5.3 Plot Kemiringan

Setelah melihat kemiringan data, perlu dilakukan pengonversian  $H_q$  menjadi *q-order mass exponent* ( $t_q$ ) lalu dikonversi menjadi *q-order singularity exponent* ( $h_q$ ) dan *q-order singularity dimension* ( $D_q$ ). Plot antara  $h_q$  vs  $D_q$  disebut sebagai *multifractal spectrum*. Kode program pengonversian  $H_q$  menjadi  $t_q$  dan pengonversian  $t_q$  menjadi  $h_q$  dan  $D_q$  dapat dilihat pada Kode Program 5.4

```
tq = Hq*qs - 1
hq = np.diff(tq) / (qs[1] -
qs[0])
```

Kode Program 5.4 q-order Exponent

Hasil plot  $D_q$  vs  $hq$  dapat dilihat pada Gambar 5.4. Selisih nilai  $hq$  maksimum dengan  $hq$  minimum disebut sebagai jarak *multifractal spectrum* atau jarak  $hq$ .



Gambar 5.4 Plot Multifractal Spectrum

### 5.2.5 Menghitung Parameter Input

Hasil *multifractal spectrum* kemudian digunakan untuk mendapatkan parameter yang akan digunakan untuk ANN yaitu jarak  $hq$  dan nilai kelengkungan. Kode program yang digunakan untuk mendapatkan parameter tersebut ada pada Kode Program 5.5.

```
b=np.polyfit(hq,Dq,2)
nilai kelengkungan = b[0]
jarak hq = max(hq)-min(hq)
```

Kode Program 5.5 Parameter

### 5.3 Uji Coba Model MFDFA

Pada tahapan ini dibuat beberapa model MFDFA dengan mengganti parameter *q-order* yang akan digunakan. Model dengan hasil signifikansi yang paling baik yang akan digunakan sebagai model ekstraksi fitur untuk *input* dari ANN. Parameter *q-order* yang digunakan sebagai model MFDFA dapat dilihat pada Tabel 5.3.

**Tabel 5.3 Model MFDFA**

Model	q-order
1	[-3,-2,-1,0,1,2,3]
2	[-5,-3,-2,-1,0,1,2,3,4,5]
3	[-10,-9,-8,-7,-6,-5,-4,-3,-2,-1,0,1,2,3,4,5,6,7,8,9,10]

Pemilihan parameter *q-order* yang digunakan pada model 1 dan 2 MFDFA didapatkan dari penelitian-penelitian mengenai algoritma MFDFA sebelumnya [8][14]. Sedangkan untuk model 3 dilakukan uji coba dengan menggunakan *q-order* yang lebih besar dari yang disarankan.

### 5.4 Uji Signifikansi Parameter

Setelah didapatkan hasil jarak *hq* dan kelengkungan selanjutnya dilakukan uji signifikansi dengan menggunakan *Wilcoxon Rank Sum Test*. Jarak *hq* dan nilai kelengkungan akan dilihat signifikansinya antara pasien dengan prognosis *good* dan *poor*. Kode Program yang akan digunakan dalam melakukan uji signifikansi ini adalah pada Kode Program 5.6.

```
p1 = ranksums(jarak_poor,jarak_good)
p2 = ranksums(kelengkungan_poor,kelengkungan_good)
```

**Kode Program 5.6 Uji Signifikansi**

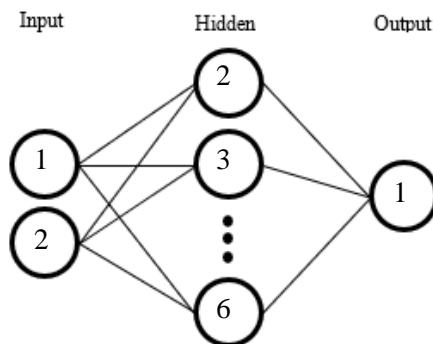
## 5.5 Klasifikasi ANN

Hasil ekstraksi fitur MFdfa yang telah lulus uji signifikansi kemudian akan menjadi input dapat proses ANN. Data akan dibagi menjadi data *training* dan *testing* dengan proporsi 70:30. Beberapa parameter yang dibutuhkan pada tahapan ANN ini adalah *input layer*, *hidden layer*, dan *output layer* seperti yang ditunjukkan pada Tabel 5.4.

Jumlah neuron dari *input layer* adalah sebanyak 2, sesuai dengan hasil dari ekstraksi fitur. Jumlah *hidden layer* yang akan digunakan adalah 1 *layer* dengan jumlah neuron yang akan ditentukan dengan melakukan *trial & error*. Jumlah neuron pada *output layer* adalah 1 yaitu apakah hasil prognosis *poor* atau *good*. Fungsi aktivasi yang digunakan pada *hidden layer* adalah sigmoid dengan *solver* lbfgs. Gambar arsitektur dari ANN yang digunakan digambarkan pada Gambar 5.5.

**Tabel 5.4 Implementasi Parameter ANN**

Parameter	Jumlah Neuron	Deskripsi
Input Layer	2 neuron	Jarak $hq$ dan nilai kelengkungan
Hidden Layer	<i>Trial &amp; Error</i>	2-6 neuron
Output Layer	1 neuron	Prognosis <i>good</i> atau <i>poor</i>
Epoch	3000	<i>Fix</i>



**Gambar 5.5 Arsitektur ANN**

Proses klasifikasi ANN ini akan dilakukan dengan menggunakan *library Python* yaitu

```
sklearn.neural_network.MLPClassifier.
```

Kode program yang digunakan pada proses klasifikasi ini adalah seperti pada Kode Program 5.7. Data akan dibagi menjadi data *training* dan *testing* menggunakan fungsi `train_test_split` yang tersedia pada *library*

```
sklearn.model_selection.train_test_split.
```

```
MLPClassifier(hidden_layer_sizes=(2,),  
activation = 'logistic', solver='lbfgs',  
max_iter = 3000,random_state=3)
```

**Kode Program 5.7 Klasifier ANN**

Hasil dari klasifikasi ANN kemudian akan diuji performanya dengan menggunakan *Confusion Matrix* sehingga didapatkan *accuracy*, *specificity* dan *sensitivity*, dan, ROCnya dengan menggunakan *library*

```
sklearn.metrics.classification_report.
```

*(halaman ini sengaja dikosongkan)*

## BAB VI

### HASIL DAN PEMBAHASAN

Bab ini akan berisi hasil dan pembahasan dari implementasi metode penelitian. Hasil yang akan dibahas pada bab ini adalah hasil dari uji signifikansi beberapa model MFDFA dan hasil klasifikasi ANN serta uji performanya.

#### 6.1 Hasil Signifikansi MFDFA

Pada sub bab ini, akan dibahas mengenai hasil dari uji signifikansi dari setiap model MFDFA yang telah dilakukan. Pada penelitian ini digunakan 3 model MFDFA dengan mengganti *q-order* yang digunakan. Parameter *q-order* yang digunakan sebagai model MFDFA dapat dilihat pada Tabel 6.1.

Tabel 6.1 Model MFDFA

Model	Parameter <i>q-order</i>
1	[-3,-2,-1,0,1,2,3]
2	[-5,-4,-3,-2,-1,0,1,2,3,4,5]
3	[-10,-9,-8,-7,-6,-5,-4,-3,-2,-1,0,1,2,3,4,5,6,7,8,9,10]

Pemilihan parameter *q-order* yang digunakan pada model 1 dan 2 MFDFA didapatkan dari penelitian-penelitian yang menggunakan MFDFA sebelumnya yang menyebutkan bahwa jarak *q-order* yang disarankan adalah dari -5 hingga 5 [8][14]. Untuk model ketiga dilakukan uji coba menggunakan *q-order* dengan *range* yang lebih besar dari yang disarankan.

Setelah didapatkan jarak *hq* dan nilai kelengkungan dari masing-masing model MFDFA, dilakukan uji signifikansi. Uji signifikansi akan dilakukan dengan *Wilcoxon Ranksum Test*. Jarak *hq* dan nilai kelengkungan dari semua pasien akan diuji signifikasinya dan fitur tersebut dinilai lulus uji apabila *p-value* yang dihasilkan  $\leq 0.05$ . Uji Signifikansi ini akan dilakukan dengan menggunakan bahasa pemrograman *python* pada semua model MFDFA yang telah ditentukan.

Hasil dari uji singnifikansi *p-value* tiap model MFDFA dapat dilihat pada Tabel 6.2.

**Tabel 6.2 Hasil Uji Signifikansi 2 Parameter**

Model	Parameter	<i>p-value</i>
1	Jarak hq	0.7755
	Nilai kelengkungan	0.6693
2	Jarak hq	0.7622
	Nilai kelengkungan	0.8256
3	Jarak hq	0.7246
	Nilai kelengkungan	0.9019

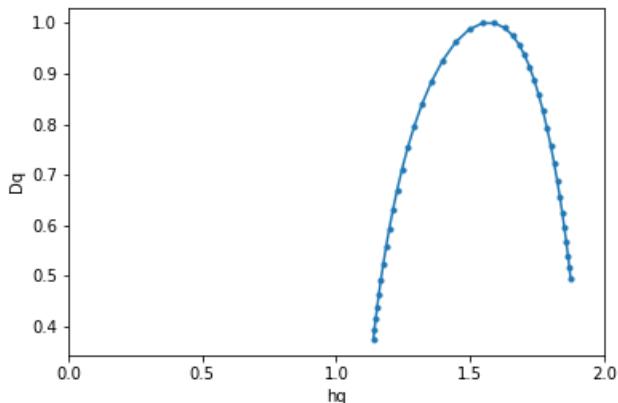
Pada model MFDFA 1, yaitu model dengan parameter *q-order* [-3,-2,-1,0,1,2,3], parameter jarak hq menghasilkan *p-value* 0.7755 dan nilai kelengkungan menghasilkan *p-value* 0.6693 sehingga tidak terdapat parameter yang dinilai signifikan karena *p-value* > 0.05 pada semua parameter sedangkan parameter baru dinilai signifikan apabila nilai *p-value* yang dihasilkan kurang dari 0.05. Apabila nilai *p-value* < 0.05, parameter tidak memiliki perbedaan yang signifikan untuk antar kelas sehingga tidak baik untuk digunakan sebagai parameter input klasifikasi ANN.

Pada model MFDFA 2, yaitu model dengan parameter *q-order* [-5,-4,-3,-2,-1,0,1,2,3,4,5], parameter jarak hq menghasilkan *p-value* 0.7622 dan parameter nilai kelengkungan menghasilkan *p-value* 0.8256 sehingga tidak terdapat parameter yang dinilai signifikan karena *p-value* > 0.05 pada semua parameter sedangkan parameter baru dinilai signifikan apabila nilai *p-value* yang dihasilkan kurang dari 0.05. Apabila nilai *p-value* < 0.05, parameter tidak memiliki perbedaan yang signifikan untuk antar kelas sehingga tidak baik untuk digunakan sebagai parameter input klasifikasi ANN.

Pada model MFDFA 3, yaitu model dengan parameter *q-order* [-10,-9,-8,-7,-6,-5,-4,-3,-2,-1,0,1,2,3,4,5,6,7,8,9,10], parameter jarak hq menghasilkan *p-value* 0.7246 dan parameter nilai kelengkungan menghasilkan *p-value* 0.9019 sehingga tidak terdapat parameter yang dinilai signifikan karena *p-value* > 0.05 pada semua parameter sehingga sama seperti hasil uji signifikansi model 2, parameter tidak memiliki perbedaan yang signifikan untuk antar kelas dan tidak baik untuk digunakan sebagai parameter input klasifikasi ANN.

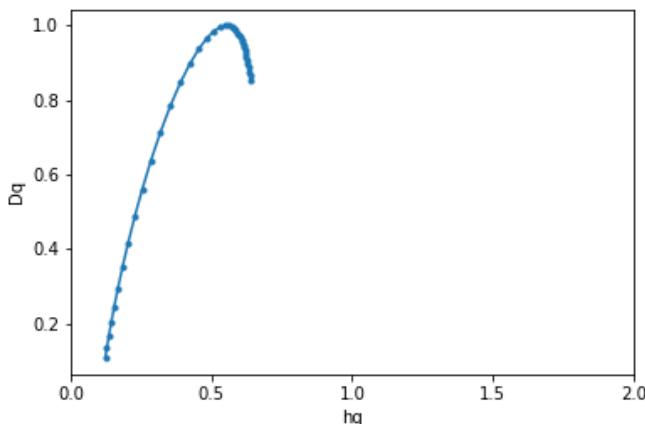
Karena tidak ada parameter yang lulus uji signifikansi, dilakukan perhitungan parameter lain yaitu rata-rata hq dan standar deviasi hq. Rata-rata hq didapatkan dengan cara menghitung rata-rata dari hq dan standar deviasi hq didapatkan dengan cara menghitung standar deviasi dari hq.

Pemilihan parameter rata-rata hq dan standar deviasi hq didasari oleh hipotesis adanya perbedaan signifikan antara pasien dengan prognosis *good* dan *poor*. Gambar 6.1 adalah hasil plot *multifractal spectrum* dari pasien yang memiliki prognosis *good*.



Gambar 6.1 Multifractal Spectrum Good. Nilai jarak  $hq = 0.737$ , nilai kelengkungan =  $-4.131$ , rata-rata  $hq = 1.519$ , dan standar deviasi  $hq = 0.275$

Gambar 6.2 adalah hasil plot *multifractal spectrum* dari pasien yang memiliki prognosis *poor*.



Gambar 6.2 Multifractal Spectrum Poor. Nilai jarak  $hq = 0.517$ , nilai kelengkungan =  $-5.244$ , rata-rata  $hq = 0.455$ , dan standar deviasi  $hq = 0.186$

Setelah didapatkan nilai rata-rata hq dan standar deviasi hq dari masing-masing model MFDFA, dilakukan uji signifikansi lagi untuk masing-masing model MFDFA. Hasil uji signifikansi dengan 4 parameter dari masing-masing model MFDFA dapat dilihat pada Tabel 6.3.

**Tabel 6.3 Hasil Uji Signifikansi 4 Parameter**

<b>Model</b>	<b>Parameter</b>	<b>Rata-Rata <i>Good</i></b>	<b>Rata-Rata <i>Poor</i></b>	<b><i>p-value</i></b>
1	Jarak hq	1.17±1.32	1.06±1.1	0.7755
	Nilai kelengkungan	- 4.33±10.2	-6.4±12.4	0.6693
	Rata-rata hq	1.14±0.62	1.01±0.5	0.0366
	Standar deviasi hq	0.48±0.63	0.42±0.52	0.8043
2	Jarak hq	1.25±1.31	1.13±1.09	0.7622
	Nilai kelengkungan	-5.2±9.84	-6.06±9.68	0.8256
	Rata-rata hq	1.13±0.63	0.99±0.51	0.0394
	Standar deviasi hq	0.54±0.64	0.48±0.53	0.7813
3	Jarak hq	1.29±1.30	1.17±1.08	0.7246
	Nilai kelengkungan	-5.9±10.1	-6.52±9.1	0.9019
	Rata-rata hq	1.12±0.63	0.98±0.51	0.0382
	Standar deviasi hq	0.59±0.64	0.53±0.53	0.7227

Pada model 1, yaitu model MFDFA dengan parameter *q-order* [-3,-2,-1,0,1,2,3], parameter rata-rata hq menghasilkan *p-value* 0.0366 sehingga terdapat 1 parameter yang telah memiliki nilai *p-value* < 0.05, yaitu nilai kelengkungan dan rata-rata hq. Oleh karena itu, parameter nilai kelengkungan dan rata-rata hq dianggap memiliki perbedaan yang signifikan antar kelas.

Pada model 2, yaitu model MF DFA dengan parameter *q-order* [-5,-4,-3,-2,-1,0,1,2,3,4,5], parameter rata-rata hq menghasilkan *p-value* 0.0394 sehingga terdapat 1 parameter yang telah memiliki nilai *p-value* < 0.05, yaitu rata-rata hq. Oleh karena itu, parameter nilai rata-rata hq dianggap memiliki perbedaan yang signifikan antar kelas.

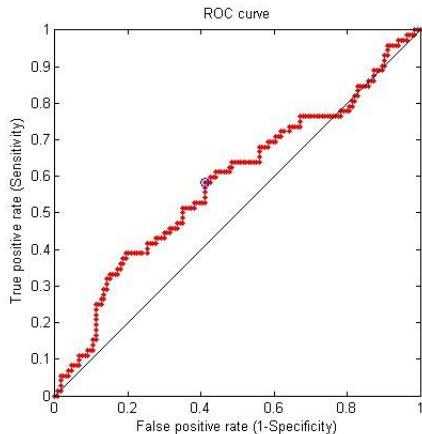
Pada model 3, yaitu model MF DFA dengan parameter *q-order* [-10,-9,-8,-7,-6,-5,-4,-3,-2-1,0,1,2,3,4,5,6,7,8,9,10], parameter rata-rata hq menghasilkan *p-value* 0.0382 sehingga terdapat 1 parameter yang telah memiliki nilai *p-value* < 0.05, yaitu rata-rata hq. Oleh karena itu, sama seperti model 2, parameter nilai rata-rata hq dianggap memiliki perbedaan yang signifikan antar kelas.

Setelah ditambahkan dua parameter baru yaitu rata-rata hq dan standar deviasi hq, didapatkan bahwa untuk ketiga model MF DFA terdapat satu parameter yang lulus uji signifikansi yaitu rata-rata hq.

## 6.2 Hasil Klasifikasi 1 Parameter Input

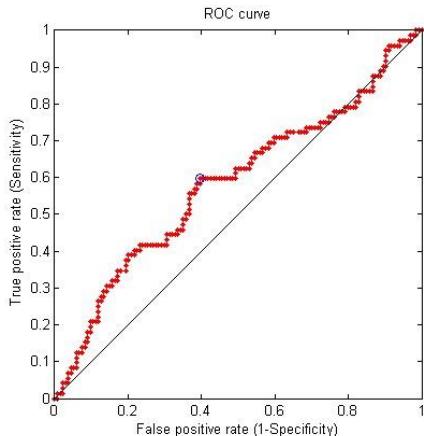
Karena hanya terdapat satu parameter yang lulus uji signifikansi, maka dilakukan klasifikasi menggunakan *cut-off value*. Dari hasil klasifikasi tersebut didapatkan nilai ROC untuk masing-masing model MF DFA.

Untuk model MF DFA 1, yaitu MF DFA dengan parameter *q-order* [-3,-2,-1,0,1,2,3], menghasilkan akurasi 58.25%, nilai ROC 0.58458, dan *p-value* 0.022641 dengan menggunakan *cut-off point* 0.9995. Kurva ROC dapat dilihat pada Gambar 6.3 dan *confusion matrix* dapat dilihat pada Tabel 6.4.

**Gambar 6.3 ROC Model MFDFA 1****Tabel 6.4 Confusion Matrix Model MFDFA 1**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	78	30	116
Negatif	56	42	98
Total	134	72	206

Untuk model MFDFA 2, yaitu MFDFA dengan parameter  $q\text{-order}$  [-5,-4,-3,-2,-1,0,1,2,3,4,5] menghasilkan akurasi 59.7%, nilai ROC 0.58344, dan  $p\text{-value}$  0.024160 dengan menggunakan *cut-off point* 0.9924. Kurva ROC dapat dilihat pada Gambar 6.4 dan *confusion matrix* dapat dilihat pada Tabel 6.5.

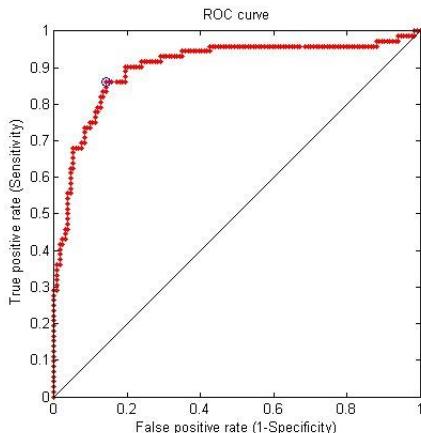


**Gambar 6.4 ROC Model MFDFA 2**

**Tabel 6.5 Confusion Matrix Model MFDFA 2**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	80	29	109
Negatif	54	43	97
Total	134	72	206

Untuk model MFDFA 3, yaitu MFDFA dengan parameter  $q\text{-order}$   $[-10, -9, -8, -7, -6, -5, 4, -3, -2, -1, 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10]$  menghasilkan akurasi 85.43%, nilai ROC 0.90278, dan  $p\text{-value}$  0.000000 dengan menggunakan *cut-off point* 0.7650. Kurva ROC dapat dilihat pada Gambar 6.5 dan *confusion matrix* dapat dilihat pada Tabel 6.6.

**Gambar 6.5 ROC Model MFDFA 3****Tabel 6.6 Confusion Matrix Model MFDFA 3**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	114	10	124
Negatif	20	62	82
Total	134	72	206

Dari klasifikasi pada ketiga model MFDFA dengan menggunakan *cut-off value*, dapat diketahui bahwa akurasi tertinggi dihasilkan dari model MFDFA 3, yaitu MFDFA dengan parameter *q-order* [-10,9,-8,-7,-6,-5,4,-3,-2,-1,0,1,2,3,4,5,6,7,8,9,10] seperti yang ditunjukkan pada tabel Tabel 6.7.

**Tabel 6.7 Hasil Klasifikasi Cut-Off Values**

Model	Akurasi	Nilai ROC	p-value	Cut-off Point
1	58.25%	0.58458	0.022641	0.9995
2	59.7%	0.58344	0.024160	0.9924
3	85.43%	0.90278	0.00000	0.7650

### 6.3 Hasil Klasifikasi ANN

Setelah dilakukan klasifikasi dengan 1 parameter menggunakan metode *cut-off value*, dilakukan uji coba klasifikasi dengan menggunakan semua parameter menggunakan metode ANN. Karena hasil akurasi yang dihasilkan dari ketiga model MFDFA dengan *hidden neuron* di atas 4 yaitu 5-12 (lihat lampiran C), tidak ada yang lebih baik dari sebelumnya, maka klasifikasi dengan jumlah *hidden neuron* yang lebih besar dari 6 tidak dilakukan dengan asumsi hasil akurasi yang didapatkan tidak lebih baik dari hasil akurasi yang didapatkan dengan menggunakan *hidden neuron* 1-4.

#### 6.2.1 Hasil Confusion Matrix

Tahapan pertama saat melakukan klasifikasi adalah mendapatkan *confusion matrix*. *Confusion matrix* untuk masing-masing model MFDFA telah didapatkan.

##### 6.2.1.1 Hasil Confusion Matrix Model MFDFA 1

Hasil *confusion matrix* yang didapatkan dari model MFDFA 1 dengan *q-order* [-3,-2,-1,0,1,2,3] dapat dilihat pada Tabel 6.8, Tabel 6.9, Tabel 6.10, Tabel 6.11, dan Tabel 6.12.

**Tabel 6.8 Confusion Matrix 2 Hidden Neuron Model MFDFA 1**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	39	5	44
Negatif	15	3	18
Total	54	8	62

Hasil yang diperoleh dengan menggunakan 2 neuron *hidden layer* pada model 1 adalah terdapat 39 nilai positif yang terdeteksi sebagai positif (*True Positive*), 5 nilai negatif yang

terdeteksi sebagai positif (*False Positive*), 15 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 3 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.9 Confusion Matrix 3 Hidden Neuron Model MFDFA 1**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	35	9	44
Negatif	13	5	18
Total	48	14	62

Hasil yang diperoleh dengan menggunakan 3 neuron *hidden layer* pada model 1 adalah terdapat 35 nilai positif yang terdeteksi sebagai positif (*True Positive*), 9 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 13 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 5 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.10 Confusion Matrix 4 Hidden Neuron Model MFDFA 1**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	38	6	44
Negatif	15	3	18
Total	53	9	62

Hasil yang diperoleh dengan menggunakan 4 neuron *hidden layer* pada model 1 adalah terdapat 38 nilai positif yang terdeteksi sebagai positif (*True Positive*), 6 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 15 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 3 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.11 Confusion Matrix 5 Hidden Neuron Model MFDFA 1**

Hasil Tes	Kondisi

Diagnostik	Positif	Negatif	Total
Positif	31	13	44
Negatif	14	4	18
Total	45	17	62

Hasil yang diperoleh dengan menggunakan 5 neuron *hidden layer* pada model 1 adalah terdapat 31 nilai positif yang terdeteksi sebagai positif (*True Positive*), 13 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 14 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 4 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.12 Confusion Matrix 6 Hidden Neuron Model MFDFA 1**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	40	4	44
Negatif	16	2	18
Total	56	6	62

Hasil yang diperoleh dengan menggunakan 6 neuron *hidden layer* pada model 1 adalah terdapat 40 nilai positif yang terdeteksi sebagai positif (*True Positive*), 16 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 4 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 2 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

#### 6.2.1.2 Hasil Confusion Matrix Model MFDFA 2

Hasil *confusion matrix* yang didapatkan dari model MFDFA 2 dengan *q-order* [-5,-4,-3,-2,-1,0,1,2,3,4,5] dapat dilihat pada Tabel 6.13, Tabel 6.14, Tabel 6.15, Tabel 6.16, dan Tabel 6.17.

**Tabel 6.13 Confusion Matrix 2 Hidden Neuron Model MFDFA 2**

Hasil Tes	Kondisi
-----------	---------

Diagnostik	Positif	Negatif	Total
Positif	39	5	44
Negatif	14	4	18
Total	53	9	62

Hasil yang diperoleh dengan menggunakan 2 neuron *hidden layer* pada model 2 adalah terdapat 39 nilai positif yang terdeteksi sebagai positif (*True Positive*), 5 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 14 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 4 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.14 Confusion Matrix 3 Hidden Neuron Model MFDFA 2**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	41	3	44
Negatif	16	2	18
Total	57	5	62

Hasil yang diperoleh dengan menggunakan 3 neuron *hidden layer* pada model 2 adalah terdapat 41 nilai positif yang terdeteksi sebagai positif (*True Positive*), 3 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 16 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 2 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.15 Confusion Matrix 4 Hidden Neuron Model MFDFA 2**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	39	5	44
Negatif	16	2	18
Total	55	7	62

Hasil yang diperoleh dengan menggunakan 4 neuron *hidden layer* pada model 2 adalah terdapat 39 nilai positif yang terdeteksi seagai positif (*True Positive*), 5 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 16 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 2 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.16 Confusion Matrix 5 Hidden Neuron Model MFDFA 2**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	35	9	44
Negatif	14	4	18
Total	49	13	62

Hasil yang diperoleh dengan menggunakan 5 neuron *hidden layer* pada model 2 adalah terdapat 35 nilai positif yang terdeteksi seagai positif (*True Positive*), 9 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 14 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 4 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.17 Confusion Matrix 6 Hidden Neuron Model MFDFA 2**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	31	13	44
Negatif	16	2	18
Total	47	15	62

Hasil yang diperoleh dengan menggunakan 6 neuron *hidden layer* pada model 2 adalah terdapat 31 nilai positif yang terdeteksi seagai positif (*True Positive*), 13 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 16 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 2 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

### 6.2.1.3 Hasil Confusion Matrix Model 3

Hasil *confusion matrix* yang didapatkan dari model MFDFA 2 dengan *q-order* [-10,-9,-8,-7,-6,-5,-4,-3,-2,-1,0,1,2,3,4,5,6,7,8,9,10] dapat dilihat pada Tabel 6.18, Tabel 6.19, Tabel 6.20, Tabel 6.21, dan Tabel 6.22.

**Tabel 6.18 Confusion Matrix 2 Hidden Neuron Model MFDFA 3**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	35	9	44
Negatif	14	4	18
Total	49	13	62

Hasil yang diperoleh dengan menggunakan 2 neuron *hidden layer* pada model 3 adalah terdapat 35 nilai positif yang terdeteksi sebagai positif (*True Positive*), 9 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 14 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 4 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.19 Confusion Matrix 3 Hidden Neuron Model MFDFA 3**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	31	13	44
Negatif	11	7	18
Total	42	20	62

Hasil yang diperoleh dengan menggunakan 3 neuron *hidden layer* pada model 3 adalah terdapat 31 nilai positif yang terdeteksi sebagai positif (*True Positive*), 13 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 11 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 7 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.20 Confusion Matrix 4 Hidden Neuron Model MFDFA 3**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	36	8	44
Negatif	12	6	18
Total	48	14	62

Hasil yang diperoleh dengan menggunakan 4 neuron *hidden layer* pada model 3 adalah terdapat 36 nilai positif yang terdeteksi sebagai positif (*True Positive*), 8 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 12 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 6 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.21 Confusion Matrix 5 Hidden Neuron Model MFDFA 3**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	31	13	44
Negatif	11	7	18
Total	42	20	62

Hasil yang diperoleh dengan menggunakan 5 neuron *hidden layer* pada model 3 adalah terdapat 31 nilai positif yang terdeteksi sebagai positif (*True Positive*), 13 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 11 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 7 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

**Tabel 6.22 Confusion Matrix 6 Hidden Neuron Model MFDFA 3**

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Positif	36	8	44
Negatif	15	3	18

Hasil Tes Diagnostik	Kondisi		
	Positif	Negatif	Total
Total	51	11	62

Hasil yang diperoleh dengan menggunakan 6 neuron *hidden layer* pada model 3 adalah terdapat 36 nilai positif yang terdeteksi sebagai positif (*True Positive*), 8 nilai negatif yang terdeteksi sebagai positif (*False Positive*), 15 nilai positif yang terdeteksi sebagai negatif (*False Negative*), dan 3 nilai negatif yang terdeteksi sebagai negatif (*True Negative*).

### 6.2.2 Hasil Akurasi Klasifikasi

Setelah didapatkan *confusion matrix*, dapat dilakukan perhitungan akurasi dengan rumus

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

#### 6.2.2.1 Hasil Akurasi Model MFDFA 1

Model MFDFA 1 adalah model yang menghasilkan dua parameter lulus uji signifikansi yaitu nilai kelengkungan dan rata-rata  $hq$ . Hasil akurasi klasifikasi yang dilakukan pada model MFDFA 1 dengan jumlah *neuron* pada *hidden layer* sebanyak 2-6 dapat dilihat pada Tabel 6.23.

Tabel 6.23 Akurasi Klasifikasi Model MFDFA 1

Hidden Layer Neuron	Accurac y
2	67.74%
3	64.51%
4	66.12%
5	56.45%
6	67.74%

Hasil akurasi klasifikasi pada model MFDFA 1 menunjukkan bahwa akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 2 adalah 67.74%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 3 adalah 64.51%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 4 adalah 66.12%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 5 adalah 56.45%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 6 adalah 67.74%.

#### 6.2.2.2 Hasil Akurasi Model MFDFA 2

Model MFDFA 2 adalah model yang mengasilkan satu parameter lulus uji signifikansi yaitu rata-rata  $hq$ . Hasil akurasi klasifikasi yang dilakukan pada model MFDFA 2 dengan jumlah *neuron* pada *hidden layer* sebanyak 2-6 dapat dilihat pada Tabel 6.24.

**Tabel 6.24 Akurasi Klasifikasi Model MFDFA 2**

Hidden Layer Neuron	Accurac y
2	69.35%
3	69.35%
4	66.12%
5	62.90%
6	53.22%

Hasil akurasi klasifikasi pada model MFDFA 2 menunjukkan bahwa akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 2 adalah 69.35%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 3 adalah 69.35%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 4 adalah 66.12%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 5 adalah 62.90%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 6 adalah 53.22%.

### 6.2.2.3 Hasil Akurasi Model MFDFA 3

Model MFDFA 3 adalah model yang mengasilkan satu parameter lulus uji signifikansi yaitu rata-rata  $hq$ . Hasil akurasi klasifikasi yang dilakukan pada model MFDFA 3 dengan jumlah *neuron* pada *hidden layer* sebanyak 2-6 dapat dilihat pada Tabel 6.25.

**Tabel 6.25 Akurasi Klasifikasi Model MFDFA 3**

Hidden Layer Neuron	Accurac y
2	62.90%
3	61.29%
4	67.74%
5	61.29%
6	62.90%

Hasil akurasi klasifikasi pada model MFDFA 2 menunjukkan bahwa akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 2 adalah 62.90%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 3 adalah 61.29%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 4 adalah 67.74%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 5 adalah 61.29%, akurasi dengan jumlah *neuron* pada *hidden layer* sebanyak 6 adalah 62.90%.

### 6.2.2.4 Hasil Akurasi Terbaik

Hasil klasifikasi dengan akurasi terbaik dari masing-masing model MFDFA ditunjukkan pada Tabel 6.26.

**Tabel 6.26 Hasil Akurasi Terbaik**

Model MFDFA	Parameter	p-value	Hidden Layer Neuron	Akurasi Terbaik
1	Rata-rata $hq$	0.0366	2	67.74%

2	Rata-rata hq	0.0393	2	69.35%
3	Rata-rata hq	0.0381	4	67.74%

Berdasarkan Tabel 6.26, dapat diketahui bahwa model MFDFA yang memiliki nilai akurasi paling baik adalah model 2 yaitu sebesar 69.35% dengan 2 neuron pada *hidden layer*. Sedangkan model 1 menghasilkan akurasi sebesar 67.74% dengan 2 neuron pada *hidden layer* dan model 3 menghasilkan akurasi sebesar 67.74% pada semua model ANN dengan jumlah neuron pada *hidden layer* 2 hingga 6. Sepuluh data pertama beserta target dan hasil prediksi dari model MFDFA dengan akurasi terbaik dapat dilihat pada Tabel 6.27.

**Tabel 6.27 Target vs Hasil Prediksi**

Jarak hq	Nilai Kelengkungan	Rata-rata hq	Standar Deviasi hq	Target	Prediksi
0.835 4	-3.7640	0.8434	0.3074	good	good
0.835 0	-1.9949	0.4586	0.3223	good	poor
1.201 7	-1.2547	1.0836	0.5271	good	good
0.283 9	-14.5801	0.9803	0.0823	good	good
0.835 9	-1.7641	0.5049	0.3302	poor	poor
0.981 1	-1.9463	1.2669	0.4130	good	good
1.159 9	-1.4398	0.8657	0.4990	good	good
1.254 2	-1.9405	1.2794	0.5039	good	good
0.316 7	-13.8422	0.5700	0.1002	good	poor
1.436 2	-1.5486	0.5781	0.6012	poor	poor

### 6.2.3 Hasil Uji Performa

Setelah didapatkan akurasi dari tiap model dan diapatkan model terbaik, dilakukan uji performa untuk mengetahui apakah model terbaik tersebut sudah baik atau tidak. Dilakukan perhitungan *Accuracy*, *Spesificity*, *Sensitivity*, dan ROC dari *confusion matrix* yang telah didapatkan. Hasil pengujian performa terbaik menggunakan 1 parameter input dengan metode *cut-off values* dan 4 parameter input dengan metode ANN yang telah dilakukan didapat dilihat pada Tabel 6.28 dan Tabel 6.29.

**Tabel 6.28 Hasil Uji Performa Cut-Off Terbaik 1 Input**

Model MFdfa	Cut-off Point	Accuracy	Spesificity	Sensitivity	AUC Score
3	0.7650	85.43%	0.46	0.85	0.90

**Tabel 6.29 Hasil Uji Performa ANN Terbaik 4 Input**

Model MFdfa	Hidden Layer Neuron	Accuracy	Spesificity	Sensitivity	AUC Score
2	2	0.6935	0.74	0.44	0.55

Dari Tabel 6.28 dan Tabel 6.29 dapat diketahui bahwa metode *cut-off value* dengan 1 input dari model MFdfa terbaik yaitu MFdfa dengan parameter *q-order* [-10,-9,-8,-7,-6,-5,-4,-3,-2,-1,0,1,2,3,4,5,6,7,8,9,10] memiliki *specificity* sebesar 0.46 dan *sensitivity* sebesar 0.85, sedangkan metode ANN terbaik dengan 4 input pada model MFdfa terbaik yaitu MFdfa dengan parameter *q-order* [-5,-4,-3,-2,-1,0,1,2,3,4,5] memiliki *specificity* sebesar 0.74 dan *sensitivity* sebesar 0.44. Dengan begitu dapat diketahui bahwa nilai positif yang terprediksi dengan benar dan nilai negatif yang terprediksi dengan benar cukup baik untuk kedua metode.

#### 6.4 Kesimpulan Percobaan

Dari hasil klasifikasi dengan metode *cut-off value* dengan 1 parameter input yang signifikan, dapat diketahui bahwa model MFDFA terbaik adalah model 3 yaitu dengan parameter *q-order* [-10,-9,-8,-7,-6,-5,-4,-3,-2,-1,0,1,2,3,4,5,6,7,8,9,10] karena model tersebut menghasilkan nilai akurasi yang paling tinggi yaitu 85.43%.

Sedangkan dari hasil klasifikasi dengan metode ANN dengan 4 parameter input, dapat diketahui bahwa model MFDFA terbaik adalah model 2 yaitu dengan parameter *q-order* [-5,-4,-3,-2,-1,0,1,2,3,4,5] dan model ANN terbaik adalah dengan menggunakan fungsi aktivasi sigmoid, *solver* lbfgs, dan 2 neuron *hidden layer* karena model tersebut menghasilkan nilai akurasi yang paling tinggi yaitu 69.35%.

## **BAB VII**

### **KESIMPULAN DAN SARAN**

Bab ini akan berisikan kesimpulan dan saran yang dihasilkan dari proses pelaksanaan penelitian tugas akhir ini.

#### **7.1 Kesimpulan**

Kesimpulan yang didapatkan dari proses pelaksanaan penelitian tugas akhir ini adalah:

1. Hasil ekstraksi fitur dengan menggunakan metode MFDFA (*Multifractal Detrended Fluctuation Analysis*) adalah terdapat 1 parameter signifikan pada masing-masing model, yaitu rata-rata  $hq$  dengan *p-value* 0.0366 untuk model 1, *p-value* 0.0394 untuk model 2, dan *p-value* 0.0382 untuk model 3. Sedangkan rata-rata dari fitur rata-rata  $hq$  adalah 1.14 pada pasien *good* dan 1.01 pada pasien *poor* untuk model 1, 1.13 pada pasien *good* dan 0.99 pada pasien *poor* untuk model 2, 1.12 pada pasien *good* dan 0.98 pada pasien *poor* untuk model 3.
2. Hasil akurasi klasifikasi terbaik dari model *cut-off value* menggunakan 1 parameter input adalah sebesar 85.43% dengan ROC bernilai 0.90. Sedangkan hasil akurasi klasifikasi terbaik dari model ANN menggunakan 4 parameter input terbaik adalah sebesar 69.35% dengan ROC bernilai 0.55.

#### **7.2 Saran**

Berdasarkan hasil penelitian tugas akhir ini, saran yang dapat diberikan untuk penelitian serupa selanjutnya adalah:

1. Fitur yang diekstraksi dengan MFDFA pada penelitian ini adalah jarak  $hq$ , nilai kelengkungan, rata-rata  $hq$ , dan standar deviasi  $hq$  sehingga untuk penelitian selanjutnya dapat menambahkan fitur yang diekstraksi seperti  $Hq$  dan  $tq$  agar hasil uji signifikansi dapat menghasilkan banyak fitur yang signifikan.

2. Dapat dilakukan perbandingan dengan menggunakan metode ekstraksi fitur lain seperti *Higher Order Detrended Fluctuation Analysis* untuk mengetahui metode ekstraksi fitur terbaik untuk klasifikasi prognosis pasien ICU.
3. Dapat dilakukan klasifikasi dengan menggunakan metode lain seperti *hybrid cut-off values + ANN* atau dengan menggunakan metode yang lebih canggih seperti CNN agar didapatkan akurasi yang lebih tinggi.
4. Dapat dilakukan ekstraksi fitur dan klasifikasi dengan menggunakan data pasien ICU yang berbeda selain dari pasien dengan diagnosis SEPSIS.

## DAFTAR PUSTAKA

- [1] H. Armiani, J. Arifin, and F. Saktini, “Hubungan APACHE II Score dengan Angka Kematian Pasien di ICU RSUP Dr. Kariadi,” pp. 7–25.
- [2] F. K. Universitas Indonesia, “Rekam Medis Berorientasi Masalah,” 2009.
- [3] A. Sekulic, O. Marinkovic, V. Malenkovic, S. Trpkovic, and A. Pavlovic, “Application of APACHE II, SAPS II, SOFA and MODS scores in predicting outcome of severe acute pancreatitis (SAP),” *Eur. J. Anaesthesiol.*, vol. 31, no. p 209, 2014.
- [4] R. E. Walton and M. Torabinejad, “Prinsip dan Praktik Ilmu Endodontia,” *Jakarta EGC. Ed.*, vol. 3, pp. 36–45, 2008.
- [5] R. Gardner and M. M. Shabot, “Patient-Monitoring Systems,” no. 1994, 1995.
- [6] J. O. Johnson, *Autonomic Nervous System Physiology*. Elsevier Inc., 2013.
- [7] D. Y. Ananta, “Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Multifractal Detrended Fluctuation Analysis (MFDFA) pada Variabilitas Denyut Jantung.” 2017.
- [8] E. A. F. Ihlen, “Introduction to Multifractal Detrended Fluctuation Analysis in Matlab,” *Front. Physiol.*, vol. 3 JUN, no. June, pp. 1–18, 2012.
- [9] N. D. Astuti, “Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis pada Variabilitas Denyut Jantung.” 2018.
- [10] Putu Doddy Heka Ardana, “Aplikasi Jaringan Syaraf Tiruan (Artificial Neural Networks ) dalam Modelisasi Curah Hujan Limpasan dengan Perbandingan Dua Algoritma Pelatihan (Studi Kasus : Das Tukad Jogading ),” *Konf. Nas. Tek. Sipil 7 (KonTekS 7)*, vol. 7, no. KoNTekS 7, pp. 24–26, 2013.

- [11] N. Midha and V. Singh, "A Survey on Classification Techniques in Data Mining," *Int. J. Comput. Sci. Manag. Stud.*, vol. 16, no. 1, 2015.
- [12] T. L. Hartono, F. D. Setiaji, and I. Setyawan, "Alat Bantu Analisis Heart Rate Variability," *J. Ilm. Elektron.*, vol. 12, pp. 141–157, 2013.
- [13] P. Siwindarto, "Electronics Heart Rate Variability (HRV)," 2012.
- [14] R. Kutner, "Algorithm of the Multifractal Detrended Fluctuation Analysis ( MF-DFA ) and some remarks concerning our case Two basic sources of multifractality The aim of the MF-DFA," *Exch. Organ. Behav. Teach. J.*, 2008.
- [15] D. Wahyuningsih and I. Zuhroh, "Prediksi Inflasi Indonesia dengan model Artificial Neural Network," pp. 113–127, 2000.
- [16] R. Muzawi and N. Sahrin, "Jaringan Syaraf Tiruan dengan Teknik Backpropagation untuk Prediksi Standar Kelulusan Ujian Nasional Produktif Kompetensi di SMK (Studi Kasus di SMK Nasional Al Huda Pekanbaru) Rometdo," vol. 2, no. 2, 2016.
- [17] W. Zhu, N. Zeng, and N. Wang, "Sensitivity, Specificity, Accuracy, Associated Confidence Interval and ROC Analysis with Practical SAS Implementations," *Northeast SAS Users Gr. 2010 Heal. Care Life Sci.*, pp. 1–9, 2010.
- [18] C. M. Florkowski, "Sensitivity, Specificity, Reiver-Operating Characteristic (ROC) Curves and Likelihood Ratios: Communicating the Performance of Diagnostic Tests," *Clin. Biochem. Rev.*, vol. 29 Suppl 1, no. Suppl 1, pp. S83-7, 2008.
- [19] C. Wild, "The Wilcoxon Rank-Sum Test," vol. 2, pp. 1–10, 1988.
- [20] Parhusip, "Tata Cara Kerja di I.P.I Dewasa Rumah Sakit H. Adam Malik Medan," pp. 1–8, 2004.

## BIODATA PENULIS



Penulis penelitian tugas akhir ini lahir di Kota Surabaya pada tanggal 14 Oktober 1995. Memiliki satu orang kakak perempuan, penulis adalah anak kedua dari dua bersaudara. Saat berusia 5 tahun, penulisa dan keluarga pindah ke Kota Makassar. Penulis telah menempuh pendidikan formal di SDN Mangkura I Makassar hingga lulus pada tahun 2008, SMPN 6 Makassar pada tahun pertama kemudian melanjutkan di SMPN 8 Malang hingga lulus pada tahun 2011. Setelah itu penulis menempuh pendidikan jenjang SMA di SMA Al Hikmah Surabaya hingga lulus pada tahun 2014. Setelah lulus SMA, penulis melanjutkan pendidikan S1 Sistem Informasi di Institut Teknologi Sepuluh Nopember.

Di masa perkuliahananya, penulis aktif di berbagai organisasi dan kepanitiaan. Pada tahun pertama penulis menjadi panitia salah satu *event* BEM ITS yaitu *Young Engineer Scientist Summit ASEAN* (YESSummit ASEAN) 2014 dan *event* seminar tingkat internasional yang diadakan oleh Departemen Sistem Informasi ITS yaitu *Information Systems International Conference* (ISICO). Pada tahun kedia penulis aktif sebagai staf Biro Komunitas HMSI (Himpunan Mahasiswa Sistem Informasi) dan staf Badan Koordinator Pemandu BEM FTIik (Fakultas Teknologi Informasi dan Komunikasi) ITS. Selain itu, penulis juga aktif di kepemanduan LKMM (Latihan Keterampilan Manajemen Mahasiswa). Pada tahun ketiga, penulis menjadi *Steering Committee* pada *event* tahunan Departemen Sistem Informasi yaitu *Information Systems Expo!* 2016 dan melakukan kerja praktik di Subdiv TIK Pelindo III Tanjuk Perak pada bulan Juni hingga Agustus 2017.

Untuk mendapatkan gelar S.Kom (Sarjana Komputer), penulis mengambil topik penelitian tugas akhir klasifikasi pada laboratorium bidang minat Rekayasa Data dan Intelelegensi Bisnis. Untuk kepentingan penelitian, penulis dapat dihubungi melalui *e-mail:* [rishaditya@gmail.com](mailto:rishaditya@gmail.com)



## LAMPIRAN A : Hasil Ekstraksi Fitur MFDFA

### Hasil MFDFA Model 1

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.7377	-1.2935	1.4550	0.7973	good
1.1236	-0.8209	0.8320	0.5277	good
1.3143	-1.8456	0.9012	0.5983	good
1.6471	-0.7537	0.8810	0.7867	good
0.9528	-3.5104	1.1497	0.4167	good
1.5681	-1.1304	1.2357	0.7336	good
0.4562	-11.6237	0.6242	0.1786	good
1.1907	-2.3924	1.0172	0.5316	good
0.4460	-14.7544	0.5750	0.1632	good
1.4482	-1.7102	0.5825	0.6521	good
0.9398	-4.1875	1.2994	0.3979	good
0.8359	-1.8548	0.4525	0.3491	good
1.0684	-3.1553	0.8050	0.4694	good
0.4919	-9.7238	0.7163	0.1998	good
1.3339	-1.0940	0.7945	0.5980	good
1.2521	-1.6772	1.0853	0.5662	good
0.5916	-7.1239	0.5997	0.2446	good
1.0259	-2.3594	0.9053	0.4632	good
1.0677	-1.6156	1.1269	0.4942	good
0.1969	-31.8085	0.6331	0.0690	good
1.2274	-2.0943	1.2300	0.5544	good
5.0161	-0.1461	2.9403	2.4475	good
0.5018	-9.2217	1.4010	0.2042	good
0.4474	-13.3876	0.9805	0.1685	good

A-2

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.3278	-19.5633	0.5365	0.1190	good
0.8700	-3.4712	0.6704	0.3827	good
0.5270	-9.7530	1.0666	0.2084	good
0.8936	-2.8196	0.7922	0.3993	good
1.3129	-1.9454	0.8249	0.5937	good
8.1624	-0.0719	4.0618	4.0084	good
0.2911	-28.9691	0.7809	0.0972	good
0.3164	-15.6712	1.2167	0.1261	good
2.0009	-0.9305	1.3394	0.9351	good
0.4390	-11.6543	0.4374	0.1736	good
1.0673	-1.8168	0.9056	0.4951	good
1.5525	-1.7530	0.9858	0.6999	good
1.3472	-1.7668	1.0300	0.6167	good
1.1525	-1.6337	0.9423	0.5348	good
0.5077	-8.1050	1.0377	0.2127	good
0.5364	-8.0914	0.6738	0.2211	good
0.2428	-27.2396	0.9181	0.0880	good
0.8354	-4.3517	0.6858	0.3589	good
0.5806	-7.0575	0.4192	0.2404	good
1.4206	-1.6630	0.9553	0.6473	good
2.7661	-0.5798	1.3577	1.3104	good
1.5746	-1.2040	1.2436	0.7323	good
0.8421	-4.0742	0.5564	0.3671	good
1.2087	-0.9276	0.5339	0.5721	good
0.9060	-3.6651	0.9257	0.3944	good
0.9353	-3.4098	1.3387	0.4129	good
1.0686	-3.1458	1.1152	0.4672	good
0.4865	-10.7585	0.7906	0.1910	good

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.1894	-2.5269	1.1219	0.5274	good
1.1037	-0.7301	0.5799	0.4928	good
1.3885	-1.8810	0.9522	0.6287	good
1.1936	-2.6729	0.6341	0.5386	good
1.5632	-1.4257	1.2980	0.7184	good
1.8263	-1.1760	1.0192	0.8479	good
0.3426	-17.9066	0.5496	0.1277	good
2.0881	-0.7874	1.2640	0.9816	good
1.3815	-0.9272	0.7479	0.6382	good
0.1983	-44.5941	0.8326	0.0650	good
1.9003	-0.9855	1.0417	0.8802	good
0.8736	-3.0331	0.9791	0.3924	good
0.2786	-30.3757	0.4175	0.0916	good
1.0493	-1.8502	0.5798	0.4109	good
0.2659	-32.0762	0.9560	0.0865	good
0.6782	-5.2759	0.6703	0.2916	good
1.4697	-0.8643	1.4202	0.7002	good
1.1049	-2.3362	1.5849	0.4984	good
1.2267	-1.8430	1.1753	0.5617	good
1.7060	-1.2201	0.9226	0.7878	good
1.7377	-1.2935	1.4550	0.7973	good
1.1236	-0.8209	0.8320	0.5277	good
1.3143	-1.8456	0.9012	0.5983	good
1.6471	-0.7537	0.8810	0.7867	good
0.9528	-3.5104	1.1497	0.4167	good
1.5681	-1.1304	1.2357	0.7336	good
0.4562	-11.6237	0.6242	0.1786	good
1.1907	-2.3924	1.0172	0.5316	good

A-4

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.4460	-14.7544	0.5750	0.1632	good
1.4482	-1.7102	0.5825	0.6521	good
0.9398	-4.1875	1.2994	0.3979	good
0.8359	-1.8548	0.4525	0.3491	good
1.0684	-3.1553	0.8050	0.4694	good
0.4919	-9.7238	0.7163	0.1998	good
1.3339	-1.0940	0.7945	0.5980	good
1.2521	-1.6772	1.0853	0.5662	good
0.5916	-7.1239	0.5997	0.2446	good
1.0259	-2.3594	0.9053	0.4632	good
1.0677	-1.6156	1.1269	0.4942	good
0.1969	-31.8085	0.6331	0.0690	good
1.2274	-2.0943	1.2300	0.5544	good
5.0161	-0.1461	2.9403	2.4475	good
0.5018	-9.2217	1.4010	0.2042	good
0.4474	-13.3876	0.9805	0.1685	good
0.3278	-19.5633	0.5365	0.1190	good
0.8700	-3.4712	0.6704	0.3827	good
0.5270	-9.7530	1.0666	0.2084	good
0.8936	-2.8196	0.7922	0.3993	good
1.3129	-1.9454	0.8249	0.5937	good
8.1624	-0.0719	4.0618	4.0084	good
0.2911	-28.9691	0.7809	0.0972	good
0.3164	-15.6712	1.2167	0.1261	good
2.0009	-0.9305	1.3394	0.9351	good
0.4390	-11.6543	0.4374	0.1736	good
1.0673	-1.8168	0.9056	0.4951	good
1.5525	-1.7530	0.9858	0.6999	good

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.3472	-1.7668	1.0300	0.6167	good
1.1525	-1.6337	0.9423	0.5348	good
0.5077	-8.1050	1.0377	0.2127	good
0.5364	-8.0914	0.6738	0.2211	good
0.2428	-27.2396	0.9181	0.0880	good
0.8354	-4.3517	0.6858	0.3589	good
0.5806	-7.0575	0.4192	0.2404	good
1.4206	-1.6630	0.9553	0.6473	good
2.7661	-0.5798	1.3577	1.3104	good
1.5746	-1.2040	1.2436	0.7323	good
0.8421	-4.0742	0.5564	0.3671	good
1.2087	-0.9276	0.5339	0.5721	good
0.9060	-3.6651	0.9257	0.3944	good
0.9353	-3.4098	1.3387	0.4129	good
1.0686	-3.1458	1.1152	0.4672	good
0.4865	-10.7585	0.7906	0.1910	good
1.1894	-2.5269	1.1219	0.5274	good
1.1037	-0.7301	0.5799	0.4928	good
1.3885	-1.8810	0.9522	0.6287	good
1.1936	-2.6729	0.6341	0.5386	good
1.5632	-1.4257	1.2980	0.7184	good
1.8263	-1.1760	1.0192	0.8479	good
0.3426	-17.9066	0.5496	0.1277	good
2.0881	-0.7874	1.2640	0.9816	good
1.3815	-0.9272	0.7479	0.6382	good
0.1983	-44.5941	0.8326	0.0650	good
1.6107	-0.9471	1.4517	0.6395	poor
1.1090	-0.6879	0.9016	0.4881	poor

A-6

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.1901	-1.3896	0.9694	0.4558	poor
1.5990	-0.4626	0.9393	0.7180	poor
0.8224	-2.3001	1.1184	0.2945	poor
1.4949	-0.8159	1.2597	0.6272	poor
0.2871	-9.0501	0.6243	0.0918	poor
1.0528	-1.7295	1.0238	0.3954	poor
0.2164	-13.0979	0.5724	0.0657	poor
1.3692	-1.2466	0.5841	0.5328	poor
0.7288	-3.2017	1.2868	0.2461	poor
0.8269	-1.6083	0.5850	0.2937	poor
0.9121	-2.4256	0.8374	0.3112	poor
0.3198	-6.7010	0.7700	0.1000	poor
1.2998	-0.7470	0.8407	0.5503	poor
1.1914	-1.2578	1.0974	0.4738	poor
0.4282	-5.1596	0.6444	0.1431	poor
0.9105	-1.6708	0.9913	0.3502	poor
1.0134	-1.1142	1.2383	0.3990	poor
0.0793	-31.9393	0.6566	0.0245	poor
1.0893	-1.2052	1.2626	0.4464	poor
4.9387	-0.0935	2.8745	2.3356	poor
0.3499	-7.0684	1.4092	0.1151	poor
0.2487	-10.5918	0.9887	0.0790	poor
0.1451	-15.6026	0.5017	0.0456	poor
0.7644	-2.8691	0.7102	0.2615	poor
0.3379	-7.5849	1.0797	0.1087	poor
0.8032	-2.4931	0.7277	0.2863	poor
1.2027	-1.5436	0.8693	0.4459	poor
8.1357	-0.0653	4.0662	3.8482	poor

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.0740	-56.3537	0.7943	0.0170	poor
0.1928	-14.3984	1.1967	0.0594	poor
1.9698	-0.8708	1.3614	0.7660	poor
0.2601	-9.9311	0.4738	0.0806	poor
0.9932	-1.1779	0.9300	0.4190	poor
1.4438	-1.6023	0.9938	0.4970	poor
1.2285	-1.1917	1.0452	0.4909	poor
1.0836	-1.1651	0.9858	0.4477	poor
0.3858	-6.2122	1.0457	0.1286	poor
0.3925	-6.1094	0.6559	0.1298	poor
0.0925	-20.4760	0.9502	0.0255	poor
0.6731	-2.9955	0.6820	0.2422	poor
0.3917	-5.0293	0.4975	0.1249	poor
1.2824	-1.1042	1.0120	0.5142	poor
2.6588	-0.3513	1.4183	1.1634	poor
1.4764	-0.8009	1.2532	0.6229	poor
0.6874	-2.3875	0.6537	0.2338	poor
1.1763	-0.7260	0.6467	0.4968	poor
0.7406	-2.2636	0.8513	0.2707	poor
0.8280	-2.9867	1.3179	0.2727	poor
0.9209	-2.8619	1.1289	0.2948	poor
0.3091	-7.8406	0.7720	0.1014	poor
1.0291	-1.8236	1.1292	0.3815	poor
1.1034	-0.7049	0.7212	0.4393	poor
1.2468	-1.1049	0.9159	0.5017	poor
1.0736	-1.5787	0.6688	0.4064	poor
1.4551	-0.8122	1.2470	0.6028	poor
1.7365	-0.8202	1.0779	0.6950	poor

## A-8

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.1867	-14.6086	0.5600	0.0576	poor
2.0656	-0.7462	1.3207	0.8224	poor
1.3803	-0.5373	0.8763	0.5778	poor
0.0470	-71.8615	0.8293	0.0115	poor
1.8255	-0.8139	1.1055	0.7255	poor
0.7703	-1.9482	1.0788	0.2767	poor
0.0834	-37.5174	0.4194	0.0236	poor
1.0480	-1.3945	0.6843	0.3637	poor
0.0817	-37.9426	0.9524	0.0233	poor
0.5594	-4.2664	0.6557	0.1886	poor
1.4386	-0.5860	1.4350	0.6371	poor
0.9933	-0.9769	1.6285	0.4264	poor
1.1293	-1.2739	1.1227	0.4495	poor
1.6638	-1.1364	0.9504	0.6217	poor

## Hasil MF DFA Model 2

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.3464	-1.0281	1.4864	0.5953	good
0.4329	-8.1392	1.1940	0.1519	good
1.3365	-1.4576	1.1869	0.5611	good
0.8822	-3.5819	0.9694	0.3260	good
1.2023	-0.8268	1.1524	0.5457	good
7.6055	-0.0541	4.4628	3.6851	good
1.7042	-0.9402	1.1496	0.7501	good
1.4646	-0.9838	0.8855	0.6476	good
1.1901	-2.3363	0.9980	0.4680	good
0.7790	-3.8513	0.8822	0.2927	good

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.6171	-4.3938	0.9926	0.2327	good
0.8354	-3.7640	0.8434	0.3074	good
0.4587	-9.1923	0.7764	0.1498	good
0.7102	-3.9131	1.1318	0.2730	good
0.9248	-3.4468	1.2493	0.3423	good
0.4843	-5.2883	0.7645	0.1915	good
8.6779	-0.0618	4.4462	4.1908	good
0.7358	-4.7609	1.3361	0.2687	good
1.2542	-1.9405	1.2794	0.5039	good
7.4676	-0.0681	3.7025	3.6051	good
0.8095	-3.6096	0.8799	0.3082	good
1.1215	-0.6878	0.9155	0.5177	good
0.3863	-9.1593	0.6473	0.1340	good
0.2839	-14.5801	0.9803	0.0823	good
1.3943	-1.5587	1.0342	0.5737	good
0.1292	-38.1947	0.6184	0.0362	good
5.4849	-0.1347	2.8070	2.6067	good
1.3432	-1.5570	1.1409	0.5616	good
1.0806	-2.5646	1.0599	0.4193	good
0.3224	-12.0117	0.6363	0.1085	good
0.3407	15.0110	1.0624	0.1086	good
0.6443	-6.7258	1.3105	0.2257	good
1.1151	-2.1241	1.1338	0.4517	good
1.1284	-1.4573	1.2653	0.4914	good
0.7371	-4.1318	1.5193	0.2758	good
0.3505	-11.1425	1.2597	0.1171	good
0.8491	-3.2922	1.0152	0.3266	good
0.8135	-3.6095	0.8385	0.3084	good
0.5051	-6.4998	1.0801	0.1831	good

A-10

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.3153	-1.7106	1.1974	0.5405	good
1.0950	-1.6475	0.9045	0.4614	good
0.5717	-6.4357	1.4332	0.1949	good
1.7019	-0.9089	1.0566	0.7485	good
1.2670	-1.7471	1.1249	0.5224	good
0.2095	-21.9631	1.1506	0.0637	good
1.2833	-1.9170	1.4842	0.5147	good
1.4106	-1.3132	0.9185	0.6010	good
4.4895	-0.2137	3.2456	2.1214	good
0.5913	-5.7631	1.2409	0.2126	good
1.1663	-2.2135	1.0308	0.4610	good
0.9650	-2.1924	0.8277	0.4031	good
0.8524	-3.0945	0.9924	0.3325	good
2.0270	-0.6394	1.0815	0.9112	good
0.1218	-54.6511	0.9889	0.0329	good
1.6917	-0.8529	1.0025	0.7473	good
0.9306	-2.7318	1.0692	0.3677	good
1.0213	-1.9622	1.0945	0.4269	good
1.0231	-1.8276	1.0327	0.4281	good
1.2541	-1.6245	0.9391	0.5226	good
3.8462	-0.0663	2.7000	1.8800	good
1.3646	-1.6759	1.1647	0.5610	good
1.1807	-1.9818	1.3018	0.4813	good
0.2949	-13.9299	0.5946	0.0929	good
0.0952	-50.7395	0.5833	0.0284	good
1.3620	-1.1847	1.0077	0.5898	good
1.3846	-1.3693	1.0002	0.5870	good
1.2527	-1.4130	1.0398	0.5392	good
1.1865	-1.8957	0.9111	0.4883	good

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.3310	-11.2326	1.0269	0.1108	good
0.1433	-30.7016	0.6435	0.0441	good
0.9811	-1.9463	1.2669	0.4130	good
1.2895	-1.5392	1.0096	0.5391	good
1.3446	-0.5406	0.8022	0.6213	good
0.4385	-6.2912	0.4639	0.1549	good
0.9485	-2.2177	0.9357	0.3953	good
1.5636	-1.0645	1.1449	0.6798	good
1.2032	-1.7995	1.4841	0.4953	good
1.4736	-1.4034	1.0707	0.6136	good
1.5888	-0.9604	1.0086	0.7032	good
1.4612	-1.8154	0.9989	0.5772	good
0.9541	-1.0521	0.8811	0.4257	good
0.8670	-2.8720	1.1204	0.3402	good
1.2017	-1.2547	1.0836	0.5271	good
1.3665	-1.1552	0.5343	0.5889	good
1.0298	-2.2673	1.0297	0.4187	good
0.9887	-2.5657	0.8907	0.3940	good
0.3479	-10.4770	1.1186	0.1204	good
1.5183	-0.8393	0.7553	0.6801	good
1.0168	-2.3095	1.1073	0.4084	good
0.6365	-2.2820	0.7880	0.2694	good
0.1513	-29.9752	0.5919	0.0469	good
0.3167	-13.8422	0.5700	0.1002	good
1.3164	-1.0122	1.0088	0.5850	good
0.9322	-2.2460	1.3686	0.3884	good
0.2119	-18.3968	0.9073	0.0697	good
1.2772	-1.0734	1.1718	0.5672	good
0.5965	-2.3993	0.4554	0.2427	good

## A-12

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.1690	-22.0972	0.5646	0.0535	good
0.3421	-11.4384	1.0368	0.1136	good
1.0774	-0.7712	1.0107	0.4834	good
1.1385	-1.7539	0.6432	0.4921	good
1.5499	-1.4089	0.8911	0.6425	good
0.8846	-1.4663	0.8782	0.3889	good
1.6311	-1.2022	1.1133	0.6884	good
1.9912	-0.6503	1.1270	0.9024	good
0.4641	-5.6808	0.9233	0.1694	good
1.1599	-1.4398	0.8657	0.4990	good
0.8103	-3.8848	0.8606	0.2996	good
0.9584	-2.6950	0.9648	0.3775	good
0.2358	-13.8496	0.4228	0.0706	good
0.0740	-61.0634	0.2838	0.0229	good
0.4687	-7.4357	1.2637	0.1591	good
0.5821	-6.2098	0.8413	0.2038	good
1.2293	-1.4454	1.1201	0.5319	good
1.2293	-1.4454	1.1201	0.5319	good
1.6854	-1.0423	1.2205	0.7292	good
0.8337	-2.4947	1.1559	0.3503	good
0.8493	-3.8658	1.2349	0.3100	good
5.1024	-0.1423	2.7244	2.4382	good
0.7559	-1.2995	0.8072	0.3284	good
0.7559	-1.2995	0.8072	0.3284	good
1.0557	-2.9129	0.7176	0.3985	good
0.8350	-1.9949	0.4586	0.3223	good
0.8315	-3.7126	1.1368	0.3128	good
1.2510	-1.2845	0.7841	0.5476	good
1.1451	-1.2690	1.2120	0.4985	good

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
2.1620	-0.5556	1.3093	0.9807	good
1.2652	-1.4598	1.1200	0.5422	good
0.7732	-3.9206	0.8681	0.2891	good
4.4696	-0.2259	2.9143	2.1124	good
1.6372	-1.0825	0.9973	0.7047	good
1.5538	-0.9780	1.0960	0.6834	good
0.7602	-2.5093	0.6850	0.3223	good
0.7226	-4.0512	0.8568	0.2716	good
1.7018	-1.1037	1.4540	0.7245	poor
1.1090	-0.6629	0.8570	0.5134	poor
1.2912	-1.6257	0.9328	0.5343	poor
1.6226	-0.5407	0.9025	0.7553	poor
0.9086	-2.8000	1.1453	0.3615	poor
1.5399	-0.9342	1.2504	0.6846	poor
0.3833	-9.8863	0.6260	0.1311	poor
1.1461	-1.9994	1.0248	0.4669	poor
0.3356	-13.4136	0.5743	0.1047	poor
1.4362	-1.5486	0.5781	0.6012	poor
0.8734	-3.6037	1.2957	0.3232	poor
0.8359	-1.7641	0.5049	0.3302	poor
1.0375	-2.8164	0.8149	0.3984	poor
0.4319	-7.1064	0.7390	0.1519	poor
1.3205	-0.8617	0.8093	0.5793	poor
1.2367	-1.4617	1.0832	0.5287	poor
0.5280	-5.7184	0.6207	0.1937	poor
0.9863	-1.9087	0.9436	0.4114	poor
1.0422	-1.2370	1.1702	0.4573	poor
0.1280	-29.5509	0.6491	0.0404	poor
1.1660	-1.4945	1.2457	0.4991	poor

A-14

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
4.9748	-0.1095	2.9181	2.3952	poor
0.4437	-7.8548	1.4068	0.1574	poor
0.3509	-11.4932	0.9869	0.1160	poor
0.2333	-15.5592	0.5169	0.0745	poor
0.8456	-3.1287	0.6833	0.3317	poor
0.4481	-8.2694	1.0731	0.1543	poor
0.8833	-2.7551	0.7584	0.3531	poor
1.2845	-1.7285	0.8431	0.5284	poor
8.1537	-0.0687	4.0662	3.9401	poor
0.1830	-33.7408	0.7898	0.0468	poor
0.2758	-14.6146	1.2035	0.0911	poor
1.9973	-0.9054	1.3488	0.8652	poor
0.3730	-10.1039	0.4570	0.1240	poor
1.0368	-1.3777	0.9162	0.4578	poor
1.5476	-1.7096	0.9902	0.6166	poor
1.3186	-1.4662	1.0360	0.5573	poor
1.1252	-1.3287	0.9603	0.4945	poor
0.4682	-7.0007	1.0473	0.1713	poor
0.4821	-6.7755	0.6667	0.1752	poor
0.1743	-23.1146	0.9362	0.0528	poor
0.7774	-3.5451	0.6867	0.3000	poor
0.5171	-5.2448	0.4556	0.1865	poor
1.3783	-1.3374	0.9801	0.5841	poor
2.7237	-0.4313	1.3758	1.2423	poor
1.5363	-0.9469	1.2498	0.6799	poor
0.7929	-2.7859	0.5933	0.3102	poor
1.1938	-0.7921	0.5786	0.5441	poor
0.8454	-2.6949	0.8949	0.3350	poor
0.9174	-3.1854	1.3330	0.3530	poor

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.0465	-2.9833	1.1176	0.3935	poor
0.4059	-8.7601	0.7816	0.1414	poor
1.1443	-2.1418	1.1276	0.4579	poor
1.1037	-0.7361	0.6386	0.4754	poor
1.3291	-1.3510	0.9431	0.5664	poor
1.1632	-2.2119	0.6414	0.4782	poor
1.5146	-1.0055	1.2855	0.6654	poor
1.8035	-0.9898	1.0386	0.7808	poor
0.2666	-15.3106	0.5546	0.0874	poor
2.0879	-0.7793	1.2885	0.9171	poor
1.3815	-0.5580	0.7957	0.6111	poor
0.1218	-53.0529	0.8324	0.0310	poor
1.8709	-0.8852	1.0638	0.8145	poor
0.8427	-2.3050	1.0203	0.3440	poor
0.1677	-32.9295	0.4183	0.0458	poor
1.0493	-1.2981	0.6166	0.3886	poor
0.1583	-33.9921	0.9530	0.0440	poor
0.6380	-4.6188	0.6604	0.2426	poor
1.4575	-0.6637	1.4268	0.6690	poor
1.0636	-1.5050	1.6104	0.4589	poor
1.1920	-1.4855	1.1532	0.5093	poor
1.7018	-1.1902	0.9321	0.7203	poor

### Hasil MFDFA Model 3

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.3728	-1.2354	1.5214	0.6400	good

A-16

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.5038	-9.6306	1.1804	0.2015	good
1.3957	-1.9282	1.1927	0.6288	good
0.9432	-4.1291	0.9608	0.4008	good
1.2623	-1.5027	1.1254	0.5839	good
7.6350	-0.0703	4.4688	3.7353	good
1.7100	-0.9509	1.1370	0.7991	good
1.4840	-1.2004	0.8654	0.6898	good
1.2125	-2.5639	0.9899	0.5390	good
0.8253	-4.4954	0.8961	0.3541	good
0.6469	-5.1637	0.9603	0.2812	good
0.8726	-4.1731	0.8663	0.3761	good
0.5260	-9.9872	0.7775	0.2086	good
0.7441	-4.7903	1.1132	0.3241	good
0.9632	-3.7848	1.2428	0.4157	good
0.5130	-6.4817	0.7671	0.2236	good
8.6827	-0.0712	4.4477	4.2601	good
0.7583	-5.1386	1.3316	0.3274	good
1.2898	-2.2273	1.2746	0.5764	good
7.4676	-0.0677	3.7137	3.6641	good
0.8576	-4.3215	0.8787	0.3698	good
1.1215	-0.7317	0.8959	0.5326	good
0.4779	-12.3656	0.6494	0.1841	good
0.3003	-25.5538	0.9870	0.1146	good
1.4213	-1.7884	1.0128	0.6444	good
0.2135	-38.2758	0.6283	0.0707	good
5.4849	-0.1424	2.7781	2.6500	good
1.3734	-1.8193	1.1416	0.6246	good
1.1061	-2.8300	1.0554	0.4896	good
0.3957	-14.2081	0.6306	0.1521	good

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.3407	11.0607	1.0295	0.0837	good
0.6697	-7.0372	1.3075	0.2832	good
1.1488	-2.4698	1.1499	0.5149	good
1.1685	-1.8389	1.2625	0.5357	good
0.7901	-4.8767	1.5144	0.3367	good
0.4227	-13.0272	1.2516	0.1642	good
0.9060	-4.1875	1.0020	0.3899	good
0.8675	-4.2356	0.8306	0.3718	good
0.5659	-7.8148	1.0731	0.2326	good
1.3403	-1.9019	1.1868	0.6073	good
1.1357	-2.1440	0.9385	0.5153	good
0.6400	-7.3109	1.4087	0.2608	good
1.7337	-1.0368	1.0436	0.8035	good
1.2962	-1.9762	1.1329	0.5863	good
0.2834	-23.6961	1.1411	0.1026	good
1.3232	-2.2138	1.4859	0.5900	good
1.4507	-1.6785	0.8930	0.6633	good
4.5230	-0.2762	3.2283	2.1905	good
0.6381	-6.5025	1.2386	0.2674	good
1.2315	-2.7399	1.0253	0.5387	good
0.9876	-2.6098	0.8276	0.4450	good
0.8886	-3.7535	0.9714	0.3897	good
2.0572	-0.8236	1.0560	0.9697	good
0.1749	-42.7467	0.9698	0.0571	good
1.7265	-1.1160	0.9790	0.8047	good
0.9869	-3.3191	1.0600	0.4304	good
1.0538	-2.3600	1.0760	0.4763	good
1.0552	-2.2122	1.0684	0.4791	good
1.2926	-1.9534	0.9211	0.5852	good

A-18

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
3.8968	-0.1324	2.7075	1.9046	good
1.3785	-1.7812	1.1522	0.6264	good
1.2037	-2.1886	1.3200	0.5404	good
0.3661	-16.0104	0.5778	0.1395	good
0.1575	-52.8880	0.5827	0.0514	good
1.3942	-1.4341	0.9705	0.6438	good
1.4285	-1.7604	1.0097	0.6502	good
1.2926	-1.8151	1.0317	0.5889	good
1.2299	-2.3974	0.9056	0.5504	good
0.4049	-12.9575	1.0066	0.1574	good
0.2201	-33.7474	0.6348	0.0751	good
1.0404	-2.6765	1.2630	0.4644	good
1.3583	-2.0173	0.9926	0.6075	good
1.3649	-0.7961	0.7666	0.6465	good
0.4666	-7.3722	0.4295	0.1969	good
1.0120	-3.2970	0.9437	0.4481	good
1.5831	-1.2211	1.1164	0.7363	good
1.2619	-2.3016	1.4765	0.5629	good
1.5201	-1.7331	1.0574	0.6877	good
1.5897	-0.9810	0.9995	0.7477	good
1.4814	-1.9385	0.9998	0.6614	good
0.9743	-1.5246	0.8406	0.4559	good
0.9098	-3.5280	1.0946	0.3990	good
1.2430	-1.6954	1.0718	0.5728	good
1.4115	-1.8510	0.5211	0.6298	good
1.0834	-2.8942	1.0202	0.4798	good
1.0283	-2.9805	0.9014	0.4550	good
0.4224	-12.7380	1.1246	0.1641	good
1.5386	-0.9856	0.7195	0.7238	good

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.0643	-2.9023	1.0900	0.4706	good
0.6931	-6.1034	0.7650	0.3041	good
0.2226	-33.0976	0.5942	0.0770	good
0.4017	-15.2306	0.5768	0.1509	good
1.3693	-1.4535	0.9762	0.6329	good
0.9721	-2.8536	1.3577	0.4359	good
0.2912	-21.6887	0.8945	0.1055	good
1.3251	-1.4864	1.1554	0.6123	good
0.6304	-4.0274	0.4118	0.2804	good
0.2463	-23.2378	0.5430	0.0892	good
0.4281	-13.1066	1.0197	0.1635	good
1.0774	-0.9008	0.9895	0.4981	good
1.1722	-2.7519	0.6260	0.5394	good
1.5697	-1.5717	0.8794	0.7163	good
0.8951	-1.5634	0.8395	0.4156	good
1.6864	-1.5545	1.1134	0.7661	good
2.0069	-0.7557	1.1010	0.9525	good
0.5254	-9.1956	0.8988	0.2164	good
1.2004	-1.8613	0.8358	0.5491	good
0.8689	-4.5091	0.8595	0.3690	good
0.9973	-3.1686	0.9806	0.4392	good
0.2483	-12.7561	0.3857	0.0937	good
0.1176	-67.0701	0.2811	0.0390	good
0.5581	-8.8491	1.2333	0.2209	good
0.6188	-6.8447	0.8258	0.2596	good
1.2477	-1.6121	1.1216	0.5776	good
1.2477	-1.6121	1.1216	0.5776	good
1.7031	-1.1668	1.2212	0.7916	good
0.8573	-2.9069	1.1412	0.3891	good

A-20

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.8946	-4.3133	1.2218	0.3817	good
5.1129	-0.1530	2.7422	2.4920	good
0.7559	-1.2856	0.7670	0.3445	good
0.7559	-1.2856	0.7670	0.3445	good
1.0906	-3.2260	0.7099	0.4758	good
0.8350	-2.5672	0.4026	0.3237	good
0.8601	-4.0144	1.1380	0.3742	good
1.2851	-1.6317	0.7679	0.5939	good
1.2010	-2.1794	1.2385	0.5436	good
2.1917	-0.7895	1.2817	1.0384	good
1.2977	-1.7841	1.1120	0.5953	good
0.8456	-4.7956	0.8637	0.3566	good
4.4877	-0.2465	2.9024	2.1769	good
1.6565	-1.2721	0.9902	0.7682	good
1.5931	-1.2271	1.0696	0.7393	good
0.7764	-2.9528	0.6729	0.3541	good
0.7902	-5.2117	0.8700	0.3339	good
1.7377	-1.2935	1.4550	0.7973	poor
1.1236	-0.8209	0.8320	0.5277	poor
1.3143	-1.8456	0.9012	0.5983	poor
1.6471	-0.7537	0.8810	0.7867	poor
0.9528	-3.5104	1.1497	0.4167	poor
1.5681	-1.1304	1.2357	0.7336	poor
0.4562	-11.6237	0.6242	0.1786	poor
1.1907	-2.3924	1.0172	0.5316	poor
0.4460	-14.7544	0.5750	0.1632	poor
1.4482	-1.7102	0.5825	0.6521	poor
0.9398	-4.1875	1.2994	0.3979	poor
0.8359	-1.8548	0.4525	0.3491	poor

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.0684	-3.1553	0.8050	0.4694	poor
0.4919	-9.7238	0.7163	0.1998	poor
1.3339	-1.0940	0.7945	0.5980	poor
1.2521	-1.6772	1.0853	0.5662	poor
0.5916	-7.1239	0.5997	0.2446	poor
1.0259	-2.3594	0.9053	0.4632	poor
1.0677	-1.6156	1.1269	0.4942	poor
0.1969	-31.8085	0.6331	0.0690	poor
1.2274	-2.0943	1.2300	0.5544	poor
5.0161	-0.1461	2.9403	2.4475	poor
0.5018	-9.2217	1.4010	0.2042	poor
0.4474	-13.3876	0.9805	0.1685	poor
0.3278	-19.5633	0.5365	0.1190	poor
0.8700	-3.4712	0.6704	0.3827	poor
0.5270	-9.7530	1.0666	0.2084	poor
0.8936	-2.8196	0.7922	0.3993	poor
1.3129	-1.9454	0.8249	0.5937	poor
8.1624	-0.0719	4.0618	4.0084	poor
0.2911	-28.9691	0.7809	0.0972	poor
0.3164	-15.6712	1.2167	0.1261	poor
2.0009	-0.9305	1.3394	0.9351	poor
0.4390	-11.6543	0.4374	0.1736	poor
1.0673	-1.8168	0.9056	0.4951	poor
1.5525	-1.7530	0.9858	0.6999	poor
1.3472	-1.7668	1.0300	0.6167	poor
1.1525	-1.6337	0.9423	0.5348	poor
0.5077	-8.1050	1.0377	0.2127	poor
0.5364	-8.0914	0.6738	0.2211	poor
0.2428	-27.2396	0.9181	0.0880	poor

A-22

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
0.8354	-4.3517	0.6858	0.3589	poor
0.5806	-7.0575	0.4192	0.2404	poor
1.4206	-1.6630	0.9553	0.6473	poor
2.7661	-0.5798	1.3577	1.3104	poor
1.5746	-1.2040	1.2436	0.7323	poor
0.8421	-4.0742	0.5564	0.3671	poor
1.2087	-0.9276	0.5339	0.5721	poor
0.9060	-3.6651	0.9257	0.3944	poor
0.9353	-3.4098	1.3387	0.4129	poor
1.0686	-3.1458	1.1152	0.4672	poor
0.4865	-10.7585	0.7906	0.1910	poor
1.1894	-2.5269	1.1219	0.5274	poor
1.1037	-0.7301	0.5799	0.4928	poor
1.3885	-1.8810	0.9522	0.6287	poor
1.1936	-2.6729	0.6341	0.5386	poor
1.5632	-1.4257	1.2980	0.7184	poor
1.8263	-1.1760	1.0192	0.8479	poor
0.3426	-17.9066	0.5496	0.1277	poor
2.0881	-0.7874	1.2640	0.9816	poor
1.3815	-0.9272	0.7479	0.6382	poor
0.1983	-44.5941	0.8326	0.0650	poor
1.9003	-0.9855	1.0417	0.8802	poor
0.8736	-3.0331	0.9791	0.3924	poor
0.2786	-30.3757	0.4175	0.0916	poor
1.0493	-1.8502	0.5798	0.4109	poor
0.2659	-32.0762	0.9560	0.0865	poor
0.6782	-5.2759	0.6703	0.2916	poor
1.4697	-0.8643	1.4202	0.7002	poor
1.1049	-2.3362	1.5849	0.4984	poor

Nilai Kelengkungan	Jarak hq	Rata-Rata hq	Standar Deviasi hq	Prognosis
1.2267	-1.8430	1.1753	0.5617	poor
1.7060	-1.2201	0.9226	0.7878	poor

A-24

## LAMPIRAN B : Hasil Klasifikasi ANN

### Hasil Klasifikasi Model ANN Terbaik

Jarak hq	Nilai Kelengkungan	Rata-Rata hq	Standar Deviasi hq	Target	Prediksi
0.2095	-21.9631	1.1506	0.0637	good	good
0.1513	-29.9752	0.5919	0.0469	poor	good
1.1451	-1.2690	1.2120	0.4985	good	good
1.2293	-1.4454	1.1201	0.5319	good	good
7.6055	-0.0541	4.4628	3.6851	good	good
1.4736	-1.4034	1.0707	0.6136	good	good
1.3943	-1.5587	1.0342	0.5737	good	good
0.4843	-5.2883	0.7645	0.1915	good	good
1.3620	-1.1847	1.0077	0.5898	good	good
0.4059	-8.7601	0.7816	0.1414	poor	good
1.2527	-1.4130	1.0398	0.5392	good	good
0.9322	-2.2460	1.3686	0.3884	good	good
1.7042	-0.9402	1.1496	0.7501	good	good
1.3205	-0.8617	0.8093	0.5793	poor	good
1.0950	-1.6475	0.9045	0.4614	good	good
0.4687	-7.4357	1.2637	0.1591	good	good
0.8337	-2.4947	1.1559	0.3503	good	good
0.8524	-3.0945	0.9924	0.3325	good	good
1.2541	-1.6245	0.9391	0.5226	good	good
4.9748	-0.1095	2.9181	2.3952	poor	good
0.5821	-6.2098	0.8413	0.2038	good	good
0.6171	-4.3938	0.9926	0.2327	good	good
8.6779	-0.0618	4.4462	4.1908	good	good
0.1433	-30.7016	0.6435	0.0441	good	good

B-2

0.9174	-3.1854	1.3330	0.3530	poor	good
0.8354	-3.7640	0.8434	0.3074	good	good
0.8350	-1.9949	0.4586	0.3223	good	poor
1.2017	-1.2547	1.0836	0.5271	good	good
0.2839	-14.5801	0.9803	0.0823	good	good
0.8359	-1.7641	0.5049	0.3302	poor	poor
0.9811	-1.9463	1.2669	0.4130	good	good
1.1599	-1.4398	0.8657	0.4990	good	good
1.2542	-1.9405	1.2794	0.5039	good	good
0.3167	-13.8422	0.5700	0.1002	good	poor
1.4362	-1.5486	0.5781	0.6012	poor	poor
1.1215	-0.6878	0.9155	0.5177	poor	good
0.6443	-6.7258	1.3105	0.2257	good	good
4.4895	-0.2137	3.2456	2.1214	good	good
8.1537	-0.0687	4.0662	3.9401	poor	good
0.2758	-14.6146	1.2035	0.0911	poor	good
1.1090	-0.6629	0.8570	0.5134	poor	good
2.7237	-0.4313	1.3758	1.2423	poor	good
1.6917	-0.8529	1.0025	0.7473	good	good
0.9248	-3.4468	1.2493	0.3423	good	good
5.1024	-0.1423	2.7244	2.4382	good	good
0.8095	-3.6096	0.8799	0.3082	good	good
0.5965	-2.3993	0.4554	0.2427	good	poor
1.4646	-0.9838	0.8855	0.6476	good	good
1.0368	-1.3777	0.9162	0.4578	poor	good
1.4106	-1.3132	0.9185	0.6010	good	good
0.2119	-18.3968	0.9073	0.0697	good	good
1.1443	-2.1418	1.1276	0.4579	poor	good
1.3646	-1.6759	1.1647	0.5610	good	good

1.6226	-0.5407	0.9025	0.7553	poor	good
1.3815	-0.5580	0.7957	0.6111	poor	poor
0.4641	-5.6808	0.9233	0.1694	good	good
0.3730	-10.1039	0.4570	0.1240	poor	poor
0.3505	-11.1425	1.2597	0.1171	good	good
0.8822	-3.5819	0.9694	0.3260	good	good
0.0740	-61.0634	0.2838	0.0229	good	poor
1.1385	-1.7539	0.6432	0.4921	good	poor
1.1920	-1.4855	1.1532	0.5093	poor	good



## **LAMPIRAN C : Hasil Akurasi Klasifikasi ANN**

### **Hasil Akurasi Klasifikasi ANN Model MFDFA 1**

Hidden Layer	Accuracy
2	67.74%
3	64.52%
4	66.13%
5	56.45%
6	67.74%
7	64.52%
8	58.06%
9	54.84%
10	67.74%
11	61.29%
12	56.45%

### **Hasil Akurasi Klasifikasi ANN Model MFDFA 2**

Hidden Layer	Accuracy
2	69.35%
3	69.35%
4	66.13%
5	62.90%
6	53.23%
7	64.52%
8	67.74%
9	62.90%
10	64.52%
11	64.52%
12	54.84%

**Hasil Akurasi Klasifikasi ANN Model MF DFA 3**

Hidden Layer	Accuracy
2	62.90%
3	61.29%
4	67.74%
5	61.29%
6	62.90%
7	66.13%
8	66.13%
9	59.68%
10	61.29%
11	66.13%
12	67.74%