



TUGAS AKHIR - KS141501

# **KLASIFIKASI PENYAKIT GAGAL JANTUNG KONGESTIF MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS PADA VARIABILITAS DENYUT JANTUNG**

***CLASSIFICATION OF CONGESTIVE HEART FAILURE DISEASE USING ARTIFICIAL NEURAL NETWORK (ANN) BASED ON HIGHER-ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS FEATURE EXTRACTION ON HEART RATE VARIABILITY***

NURFIANA DWI ASTUTI  
NRP 05211440000055

Dosen Pembimbing I  
Wiwik Anggraeni, S.Si, M.Kom

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

DEPARTEMEN SISTEM INFORMASI  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember  
Surabaya 2017

## TUGAS AKHIR - KS141501

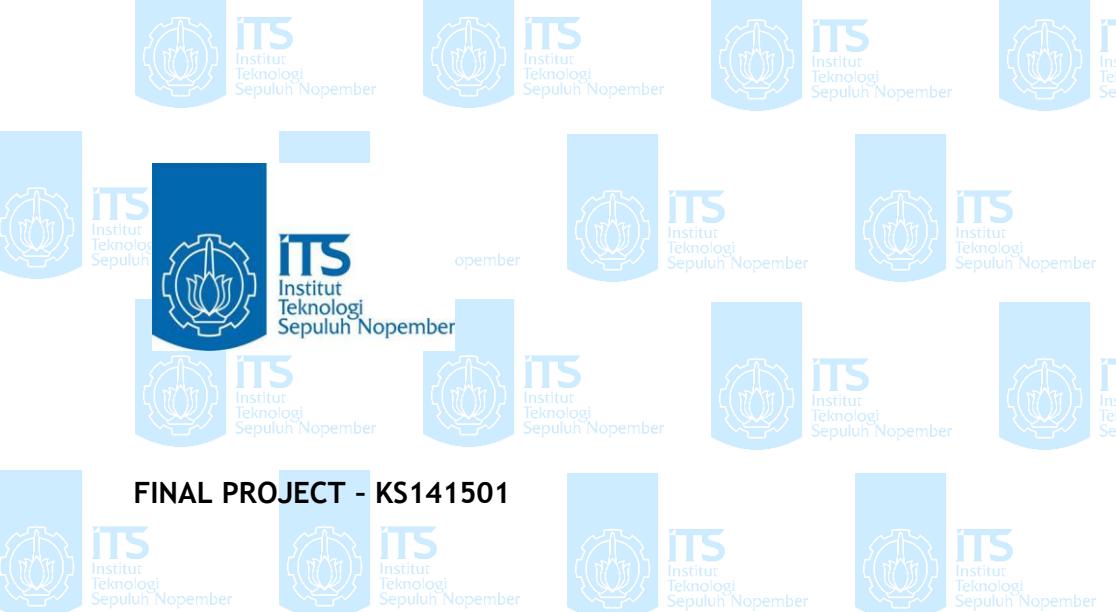
**KLASIFIKASI PENYAKIT GAGAL JANTUNG KONGESTIF MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS PADA VARIABILITAS DENYUT JANTUNG**

**NURFIANA DWI ASTUTI  
NRP 0521144000055**

Dosen Pembimbing I  
Wiwik Anggraeni, S.Si, M.Kom

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

**DEPARTEMEN SISTEM INFORMASI  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember  
Surabaya 2017**



## FINAL PROJECT - KS141501

# CLASSIFICATION OF CONGESTIVE HEART FAILURE DISEASE USING ARTIFICIAL NEURAL NETWORK (ANN) BASED ON HIGHER-ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS FEATURE EXTRACTION ON HEART RATE VARIABILITY

NURFIANA DWI ASTUTI  
NRP 05211440000055  
Supervisors I  
Wiwik Anggraeni, S.Si, M.Kom

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

INFORMATION SYSTEMS DEPARTEMEN  
Information Technology and Communication Faculty  
Sepuluh Nopember Institut of Technology  
Surabaya 2017



## LEMBAR PENGESAHAN

# KLASIFIKASI PENYAKIT GAGAL JANTUNG KONGESTIF MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS PADA VARIABILITAS DENYUT JANTUNG

## 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:

**NURFIANA DWI ASTUTI**

NRP. 5214100055

Surabaya, Januari 2018

**Pih. KEPALA  
DEPARTEMEN SISTEM INFORMASI**

**Edwin Riksakomara, S.Kom., M.T**  
**NIP.19690725 200312 1 001**

## LEMBAR PERSETUJUAN

# KLASIFIKASI PENYAKIT GAGAL JANTUNG KONGESTIF MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS PADA VARIABILITAS DENYUT JANTUNG

## 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 :

**NURFIANA DWI ASTUTI**

NPB. 5214100055

Disetujui Tim Penguji : Tanggal Ujian : Januari 2018  
Periode Wisuda: Maret 2018

**Wiwik Anggraeni, S.Si, M.Kom**

  
**(Pembimbing I)**

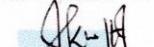
**Faizal M., S.Kom, M.Eng, Ph.D**

  
**(Pembimbing II)**

**Edwin Riksakomara, S.Kom., MT.**

  
**(Pengaji I)**

**Eko Wahyu Tyas D, S.Kom, MBA**

  
**(Pengaji II)**

X

X

**KLASIFIKASI PENYAKIT GAGAL JANTUNG  
KONGESTIF MENGGUNAKAN ARTIFICIAL NEURAL  
NETWORK (ANN) BERDASARKAN EKSTRAKSI  
FITUR HIGHER-ORDER MOMENTS DETRENDED  
FLUCTUATION ANALYSIS PADA VARIABILITAS  
DENYUT JANTUNG**

**Nama Mahasiswa : NURFIANA DWI ASTUTI  
NRP : 05211440000055  
Jurusan : SISTEM INFORMASI FTIK-ITS  
Dosen Pembimbing 1 : Wiwik Anggraeni, S.Si, M.Kom  
Dosen Pembimbing 2 : Faizal M., S.Kom, M.Eng, Ph.D**

**ABSTRAK**

*Penyakit jantung koroner atau penyakit kardiovaskular merupakan penyakit yang mempengaruhi jantung serta semua pembuluh darah di tubuh yang disebabkan oleh penumpukan plak di arteri seseorang dan dapat berakibat pada terjadinya stroke atau serangan jantung. Menurut Departemen Kesehatan Indonesia (Depkes RI) penyakit jantung koroner merupakan penyebab utama dan pertama dari seluruh kematian, yaitu sebesar 26,4%. Melihat tingginya nilai kematian tersebut, perlu adanya pendekripsi penyakit jantung demi mengurangi jumlah kematian akibat penyakit jantung. Pendekripsi penyakit jantung dapat dilakukan dengan memeriksa sinyal Heart Rate Variability (HRV). Penilaian HRV dilakukan dengan cara menganalisis rekam short-term dan long-term Electrocardiogram (ECG). Untuk menganalisis sinyal HRV, diperlukan metode ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis untuk melihat struktur non-linear dan melihat volatility behavior pada data HRV. Input dari Higher-Order Moments Detrended Fluctuation Analysis adalah sinyal ECG yang sudah diubah menjadi sinyal HRV. Output dari ekstraksi fitur tersebut*

*adalah nilai fungsi fluktuasi dan local scaling esponent berdasarkan skewness dan kurtosis pada pasien penyakit jantung dan pasien normal. Nilai tersebut kemudian digunakan sebagai input untuk klasifikasi menggunakan Artificial Neural Network. Output dari klasifikasi tersebut adalah klasifikasi pasien penyakit jantung dan pasien normal. Hasil klasifikasi ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis menghasilkan akurasi terbaik sebesar 71.43% dengan nilai ROC yaitu 0.774 yang dapat dikategorikan sebagai klasifikasi yang cukup baik. Hasil dari penelitian ini diharapkan dapat digunakan dalam penelitian selanjutnya dengan menggunakan metode klasifikasi lainnya dan dapat bermanfaat di dunia mendis untuk mendiagnosa penyakit gagal jantung kongestif pada pasien agar segera dilakukan tindakan preventif.*

**Kata kunci : Klasifikasi, Higher-Order Moments Detrended Fluctuation Analysis, Skewness, Kurtosis, Heart Rate Variability, Artificial Neural Network**

***CLASSIFICATION OF CONGESTIVE HEART  
FAILURE DISEASE USING ARTIFICIAL NEURAL  
NETWORK (ANN) BASED ON HIGHER-ORDER  
MOMENTS DETRENDED FLUCTUATION  
ANALYSIS FEATURE EXTRACTION ON HEART  
RATE VARIABILITY***

Name : NURFIANA DWI ASTUTI  
NRP : 05211440000055  
Departement : INFORMATION SYSTEM FTIK-ITS  
Supervisor 1 : Wiwik Anggraeni, S.Si, M.Kom  
Supervisor 2 : Faizal M., S.Kom, M.Eng, Ph.D

**ABSTRACT**

*Coronary heart disease or cardiovascular disease is a disease that affects the heart and all blood vessels in the body caused by the buildup of plaque in a person's arteries and can result in stroke or heart attack. According to the Indonesian Ministry of Health (MOH) coronary heart disease is the main cause of all deaths, which amounted to 26.4%. Seeing the high mortality rate, the need for detection of heart disease in order to reduce the number of deaths from heart disease come surface. Detection of heart disease can be done with the help of Heart Rate Variability (HRV) signal. The HRV assessment is performed by short-term and long-term motion of the electrocardiogram (ECG). To see the symptoms of HRV, a method is needed to view non-linear structures and to see volatility behavior on HRV data. Input from High-Order Moments Detrended Fluctuation Analysis is an ECG signal that has been converted into HRV. The result of this feature extraction is the fluctuations function and local scaling exponent based on skewness and kurtosis in patients with heart disease and normal patients. The value is then used as input for Artificial Neural Networks classification. The output*

*of this classification is the class of the patient's heart disease and the normal patient. The output of classification has the best result with 71.43% for accuracy and 0.774 for ROC value which can be categorized as a good enough classification. The results of this study are expected to be used in subsequent research by using methods of carefulness and can be useful to diagnose congestive heart failure in patients for immediate preventive action.*

***Keywords : Classification, Higher-Order Moments Detrended Fluctuation Analysis, Skewness, Kurtosis, Heart Rate Variability, Artificial Neural Network***

## **KATA PENGANTAR**

Alhamdulillah atas karunia, rahmat, barakah, dan jalan yang telah diberikan Allah SWT selama ini sehingga penulis mendapatkan kelancaran dalam menyelesaikan tugas akhir dengan judul:

### **KLASIFIKASI PENYAKIT GAGAL JANTUNG KONGESTIF MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS PADA VARIABILITAS DENYUT JANTUNG**

Terima kasih atas pihak-pihak yang telah mendukung, memberikan saran, motivasi, semangat, dan bantuan baik materi maupun spiritual demi tercapainya tujuan pembuatan tugas akhir ini. Secara khusus penulis akan menyampaikan ucapan terima kasih yang sedalam-dalamnya kepada:

1. Orang tua penulis Wiwik Ernawati, kakak terncinta Galih Putra Laksana Adi dan adik tersayang Muhammad Rasyid Iman Al-ghaffari serta keluarga besar penulis yang tidak bisa saya sebutkan satu-satu, terima kasih telah mendoakan dan mendukung penulis.
2. Ibu Wiwik Anggraeni, S.Si, M.Kom. dan Bapak Faizal Mahananto, S.Kom., M.Eng., PhD selaku dosen pembimbing yang meluangkan waktu, memberikan ilmu, petunjuk, dan motivasi untuk kelancaran Tugas Akhir ini.
3. Bapak Edwin Riksakomara, S.Kom., MT. dan Bapak Ahmad Mukhlason, S.Kom, M.Sc, Ph.D. selaku dosen pengujii yang telah memberikan masukan untuk perbaikan tugas akhir ini.
4. Seluruh civitas akademika, termasuk dosen, pada Jurusan Sistem Informasi ITS yang telah menjadi bagian hidup selama kuliah dan yang telah memberikan ilmu yang sangat berharga bagi penulis.
5. Rekan-rekan OSIRIS yang telah berjuang bersama dalam menjalani perkuliahan di Jurusan Sistem Informasi ITS. Terima kasih atas segala dukungan yang diberikan.

6. Teman-teman tercinta Cindy, Depe, Dhira, Elroy, Fia, Ninda, Nita, Nody, Patty, Rachel, Rara, Risha, Septy, Tatan, dan Yunis.Oryza Khairunnisa, serta para Pejuang RDIB yang telah melewati duka cita bersama mengerjakan tugas akhir.
7. Berbagai pihak yang membantu dalam penyusunan Tugas Akhir ini dan belum dapat disebutkan satu per satu.

Penyusunan laporan ini masih jauh dari sempurna, untuk itu saya menerima adanya kritik dan saran yang membangun untuk perbaikan di masa mendatang. Semoga buku tugas akhir ini dapat memberikan manfaat bagi pembaca.

## DAFTAR ISI

LEMBAR PENGESAHAN .....	viii
LEMBAR PERSETUJUAN .....	ix
ABSTRAK .....	v
ABSTRACT .....	vii
KATA PENGANTAR .....	ix
DAFTAR ISI .....	xi
DAFTAR GAMBAR .....	ix
DAFTAR TABEL .....	xv
DAFTAR SEGMENT PROGRAM .....	xv
BAB I PENDAHULUAN .....	1
1.1. Latar Belakang .....	1
1.2. Perumusan Masalah .....	5
1.3. Batasan Pengerjaan Tugas Akhir .....	5
1.4. Tujuan Tugas Akhir .....	5
1.5. Manfaat Tugas Akhir .....	6
1.6. Relevansi .....	7
BAB II TINJAUAN PUSTAKA .....	9
2.1. Studi Sebelumnya .....	9
2.2. Dasar Teori .....	14
2.2.1. Penyakit Jantung .....	14
2.2.2. Heart Rate Variability .....	14
2.2.3. MATLAB .....	15
2.2.4. Klasifikasi .....	16
2.2.5. Artificial Neural Network .....	16
2.2.6. Higher-Order Moments Detrended Fluctuation Analysis .....	18
2.2.7. Uji Rank Sum Wilcoxon .....	20
2.2.8. Uji Validitas .....	21
BAB III METODOLOGI PENELITIAN .....	23
3.1. Metodologi Penelitian .....	23
3.2. Tahap Perancangan .....	24
3.2.1. Studi Literatur dan Pengumpulan Data .....	24
3.2.2. Preproses Data .....	24

3.2.3.	Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis.....	24
3.2.4.	Klasifikasi ANN .....	25
3.2.5.	Analisis Hasil Klasifikasi .....	26
3.2.6.	Penarikan Kesimpulan .....	26
3.2.7.	Penyusunan Buku Laporan TA .....	26
<b>BAB IV PERANCANGAN</b>	.....	<b>29</b>
4.1.	Pengumpulan dan Pra-prosesser Data .....	29
4.1.1.	Pengumpulan Data.....	29
4.1.2.	Pra-processing data.....	29
4.2.	Perancangan Model Higher-Order Moements Detrended Fluctuation Analysis .....	30
4.3.	Menghitung Parameter Input.....	30
4.3.1.	Menghitung Parameter Fungsi Fluktuasi berdasarkan <i>Skewness</i> .....	30
4.3.2.	Menghitung Parameter Fungsi Fluktuasi berdasarkan <i>Kurtosis</i> .....	30
4.3.3.	Menghitung Parameter <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> .....	31
4.3.4.	Menghitung Parameter <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> .....	31
4.4.	Uji Signifikansi pada Parameter Input.....	31
4.4.1.	Uji Signifikansi Fungsi Fluktuasi berdasarkan <i>Skewness</i> .....	31
4.4.2.	Uji Signifikansi Fungsi Fluktuasi berdasarkan <i>Kurtosis</i> .....	32
4.4.3.	Uji Signifikansi <i>Local scaling exponent</i> berdasarkan <i>Skewness</i> .....	32
4.4.4.	Uji Signifikansi <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> .....	32
4.5.	Pemodelan ANN .....	33
4.6.	Uji Validitas .....	38
<b>BAB V IMPLEMENTASI</b>	.....	<b>39</b>
5.1.	Pra Processing Data .....	39
5.2.	Penyiapan Data Masukan .....	40
5.3.	Membagi Data.....	40

5.4.	Implementasi Higher-Order Moments Detrended Fluctuation Analysis .....	42
5.4.1.	Menghitung Integrasi Time Series.....	42
5.4.2.	Membagi Segment.....	45
5.4.3.	Menghitung Fungsi Fluktuasi berdasarkan <i>Skewness</i> dan <i>Kurtosis</i> .....	46
5.4.4.	Menghitung Nilai <i>Local Scaling Exponent</i> berdasarkan <i>Skewness</i> dan <i>Kurtosis</i> .....	47
5.4.5.	Menghitung Parameter Input .....	48
5.5.	Uji Coba Model Higher-Order Moments Detrended Fluctuation Analysis .....	48
5.6.	Uji Signifikansi Parameter .....	49
5.7.	Implementasi Klasifikasi Artificial Neural Network ...	50
5.7.1.	Pemrosesan Data .....	50
5.7.2.	Uji Klasifikasi ANN .....	51
5.8.	Uji Validitas Klasifikasi.....	51
BAB VI	HASIL DAN PEMBAHASAN .....	53
6.1.	Hasil Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis .....	53
6.2.	Hasil Signifikansi Higher-Order Moments Detrended Fluctuation Analysis .....	67
6.3.	Hasil Klasifikasi ANN .....	70
6.4.	Hasil Uji Validasi.....	74
BAB VII	KESIMPULAN DAN SARAN .....	80
7.1.	Kesimpulan .....	80
7.2.	Saran .....	81
DAFTAR PUSTAKA .....	82	
BIODATA PENULIS .....	86	
LAMPIRAN A .....	A-1	
LAMPIRAN B .....	B-1	



*(Halaman ini sengaja dikosongkan)*



## **DAFTAR GAMBAR**

Gambar 2.1 Gelombang ECG Normal .....	15
Gambar 2.2.2 Jaringan ANN Multilayer (Fauset, 1994).....	18
Gambar 3.1 Metodologi Penelitian.....	23
Gambar 4.1 Struktur Model ANN untuk <i>Hidden Layer</i> Node Sejumlah 2 .....	35
Gambar 4.2 Struktur Model ANN untuk <i>Hidden Layer</i> Node Sejumlah 3 .....	36
Gambar 4.3 Struktur Model ANN untuk <i>Hidden Layer</i> Node Sejumlah 4 .....	37
Gambar 4.4 Struktur Model ANN untuk <i>Hidden Layer</i> Node Sejumlah 16 .....	37
Gambar 4.5 Struktur Model ANN untuk <i>Hidden Layer</i> Node Sejumlah 20 .....	38
Gambar 5.1 Noise Like Time Series .....	44
Gambar 5.2 Random Walk Time Series .....	44
Gambar 5.3 Menu Test Option pada Weka .....	51
Gambar 5.4 Contoh Hasil Klasifikasi ANN .....	52
Gambar 6.1 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai <i>Skewness</i> untuk CHF1 .....	54
Gambar 6.2 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai Skewness untuk CHF2 .....	54
Gambar 6.3 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai Skewness untuk NSR .....	55
Gambar 6.4 Plot Fungsi Fluktuasi berdasarkan <i>Skewness</i> untuk Data CHF1 .....	55
Gambar 6.5 Plot Fungsi Fluktuasi berdasarkan <i>Skewness</i> untuk Data CHF2 .....	56
Gambar 6.6 Plot Fungsi Fluktuasi berdasarkan <i>Skewness</i> untuk Data NSR .....	56
Gambar 6.7 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk CHF1 .....	57
Gambar 6.8 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk CHF2 .....	58
Gambar 6.9 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk NSR .....	58

Gambar 6.10 Plot Fungsi Fluktuasi berdasarkan <i>Kurtosis</i> untuk Data CHF1 .....	59
Gambar 6.11 Plot Fungsi Fluktuasi berdasarkan <i>Kurtosis</i> untuk Data CHF2 .....	59
Gambar 6.12 Plot Fungsi Fluktuasi berdasarkan <i>Kurtosis</i> untuk Data NSR .....	60
Gambar 6.13 Contoh Plot <i>Local Scaling Exponent</i> berdasarkan <i>Skewness</i> untuk CHF1 .....	61
Gambar 6.14 Contoh Plot <i>Local Scaling Exponent</i> berdasarkan <i>Skewness</i> untuk CHF2 .....	61
Gambar 6.15 Contoh Plot <i>Local scaling exponent</i> berdasarkan <i>Skewness</i> untuk NSR .....	62
Gambar 6.16 Hasil Plot <i>Local scaling exponent</i> berdasarkan <i>Skewness</i> untuk Data CHF1.....	62
Gambar 6.17 Hasil Plot <i>Local scaling exponent</i> berdasarkan <i>Skewness</i> untuk Data CHF2.....	63
Gambar 6.18 Hasil Plot <i>Local scaling exponent</i> Berdasarkan <i>Skewness</i> Untuk Data NSR.....	63
Gambar 6.19 Contoh Plot <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> untuk CHF1 .....	64
Gambar 6.20 Contoh Plot <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> untuk CHF2 .....	65
Gambar 6.21 Contoh Plot <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> untuk NSR .....	65
Gambar 6.22 Hasil Plot <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> untuk Data CHF1 .....	66
Gambar 6.23 Hasil Plot <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> untuk Data CHF2 .....	66
Gambar 6.24 Hasil Plot <i>Local scaling exponent</i> berdasarkan <i>Kurtosis</i> untuk Data NSR .....	67



*(Halaman ini sengaja dikosongkan)*

## DAFTAR TABEL

Tabel 2.1 Studi Literatur1 .....	9
Tabel 2.2 Studi Literatur 2 .....	10
Tabel 2.3 Studi Literatur 3 .....	11
Tabel 2.4 Studi Literatur 4 .....	12
Tabel 2.5 Studi Literatur 5 .....	13
Tabel 2.6 Kriteria Keakuratan Klasifikasi Menggunakan ROC .....	22
Tabel 4.1 Uji Model ANN.....	34
Tabel 5.1 Pra Proses Data ECG ke HRV.....	39
Tabel 5.2 Uji Coba MFDFA.....	48
Tabel 6.1 Hasil Signifikansi output Higher-Order Moments Detrended Fluctuation Analysis .....	68
Tabel 6.2 Sebagian Hasil Uji Klasifikasi untuk Panjang Data 15 menit .....	71
Tabel 6.3 Sebagian Hasil Uji Klasifikasi untuk Panjang Data 20 menit .....	71
Tabel 6.4 Hasil Klasifikasi output Higher-Order Moments Detrended Fluctuation Analysis .....	72
Tabel 6.5 Contoh Hasil Klasifikasi ANN Prediksi dengan Status.....	73
Tabel 6.6 <i>Confusion Matrix</i> untuk Hasil Klasifikasi pada Data 15 Menit.....	75
Tabel 6.7 Nilai <i>Precision</i> dan <i>Recall</i> untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 15 Menit .....	75
Tabel 6.8 <i>Confusion Matrix</i> untuk Hasil Klasifikasi pada Data 20 Menit.....	76
Tabel 6.9 Nilai <i>Precision</i> dan <i>Recall</i> untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 20 Menit .....	76
Tabel 6.10 Hasil Uji Validasi .....	77

*(Halaman ini sengaja dikosongkan)*

## **DAFTAR SEGMENT PROGRAM**

Segmen Program 5.1 .....	41
Segmen Program 5.3 .....	42
Segmen Program 5.2 .....	43
Segmen Program 5.4 .....	45
Segmen Program 5.5 .....	46
Segmen Program 5.6 .....	46
Segmen Program 5.7 .....	46
Segmen Program 5.8 .....	47
Segmen Program 5.9 .....	47
Segmen Program 5.10 .....	48
Segmen Program 5.11 .....	48
Segmen Program 5.12 .....	49



## **BAB I**

### **PENDAHULUAN**

Pada bab pendahuluan ini akan menjelaskan mengenai latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, dan manfaat kegiatan tugas akhir. Berdasarkan uraian pada bab ini, diharapkan mampu memberi gambaran umum permasalahan dan pemecahan masalah pada tugas akhir.

#### **1.1. Latar Belakang**

Penyakit jantung koroner adalah penyebab utama kecacatan dan kematian dini di seluruh dunia, dan berkontribusi secara substansial terhadap meningkatnya biaya perawatan kesehatan [1]. Berdasarkan statistik yang didapatkan oleh American Heart Assosiation (AHA), pada tahun 2013 penyakit jantung koroner menyebabkan 1 kematian dari 7 kematian yang ada di Amerika. Pada tahun 2013, AHA mencatat jumlah kematian akibat penyakit jantung koroner adalah sebanyak 370.213 orang [2]. Menurut World Health Organization (WHO), pada tahun 2012 tercatat 7,4 juta orang di dunia meninggal karena penyakit jantung koroner [3]. Sedangkan untuk di Indonesia sendiri berdasarkan data dari survei Sample Registration System (SRS) pada tahun 2014 menunjukan bahwa penyakit jantung koroner merupakan penyebab kematian tertinggi pada semua umur yaitu sebesar 12,9%. Data dari Riskesdas pada tahun 2013 menunjukan bahwa prevalensi tertinggi untuk penyakit Kardiovaskuler di Indonesia adalah penyakit jantung koroner yaitu sebesar 1,5% [3]. Melihat angka kematian yang cukup besar, muncul pemikiran bahwa perlu adanya pendekripsi penyakit jantung demi mengurangi jumlah kematian akibat penyakit jantung.

Untuk mendiagnosa penyakit gagal jantung, dokter akan mengambil data rekam medis dari pasien kemudian memeriksa gejala yang ada. Dokter juga akan memeriksa persentase faktor risiko yang ada, seperti tekanan darah tinggi, Coronary Artery Disease (CAD), atau diabetes [4]. Namun,

pemeriksaan tersebut membutuhkan waktu yang lama karena dokter harus melakukan tes satu per satu baru kemudian melakukan analisis untuk mendapatkan diagnosa yang tepat. Oleh karena itu, dibutuhkan suatu metode analysis yang dapat mendeteksi penyakit jantung dalam waktu yang cepat.

Salah satu solusi untuk mendeteksi penyakit jantung dengan cepat adalah dengan menganalisis sinyal HRV dari pasien. Kondisi pasien dengan kondisi gagal jantung dapat diperiksa dengan sinyal Heart Rate Variability (HRV) [5]. Sinyal HRV mencerminkan interaksi antara dua subsistem ANS (simpatik dan parasimpatik) yang mempengaruhi sistem kardiovaskular [6]. Sinyal HRV dapat digunakan untuk menentukan kondisi pasien saat ini [5]. Penilaian HRV dilakukan dengan cara menganalisis rekam short-term dan long-term Electrocardiogram (ECG) [6]. ECG itu sendiri adalah rekam gelombang aktivitas kelistrikan jantung yang terdiri dari gelombang P, kompleks gelombang QRS, dan gelombang T. Besar amplitudo dari sinyal ECG bervariasi, tergantung pada pemasangan elektroda dan kondisi fisik dari pasien [5]. Dengan rekam ECG, para dokter dapat menentukan kondisi jantung dari pasien [5] karena hasil perekaman ECG menunjukkan karakteristik dari jantung [7].

Sinyal HRV merupakan sinyal dengan struktur nonlinear [8] dan pola data yang non-stationer. Sinyal HRV juga memiliki sifat invarian terhadap skala. Sinyal HRV memiliki karakteristik non-stasioner, menunjukkan korelasi jarak jauh (memory) dan variabilitas instans (volatility) [9]. Oleh karena itu, metode yang cocok digunakan untuk mengolah sinyal HRV adalah Detrended Fluctuation Analysis karena metode tersebut cocok digunakan untuk data yang memiliki struktur nonlinear dan non-stationer [10]. Metode yang digunakan untuk penelitian ini adalah Higher-Order Moments Defrended Fluctuation Analysis. Metode Higher-Order Moments Defrended Fluctuation Analysis akan memeriksa volatilitas penskalaan properti (volatility scaling property) yang ada pada sinyal HRV denyut jantung. Higher-Order Moments

Detrended Fluctuation Analysis merupakan metode yang lebih cocok dibandingkan dengan Detrended Fluctuation Analysis karena metode ini menghitung *skewness* dan *kurtosis* dari sinyal HRV. *Skewness* menunjukkan nilai asimetri distribusi probabilitas dari variabel acak bernilai riil tentang meannya. Sedangkan *kurtosis* menunjukkan nilai perubahan dari tailedness. Nilai *skewness* dan *kurtosis*, akan menunjukkan sifat volatilitas yang ada pada data time series dalam aspek yang berbeda sehingga dapat menghasilkan informasi yang lebih menarik [11].

Hasil ekstrasi fitur menggunakan Higher-Order Moments Detrended Fluctuation Analysis akan dijadikan input untuk klasifikasi dengan menggunakan metode Artificial Neural Network demi mengetahui perbedaan sinyal HRV pada pasien penyakit gagal jantung dan pasien normal. Artificial Neural Network sangat ideal untuk memprediksi penyakit pada pasien. Artificial Neural Network secara khusus sesuai dengan korelasi nonlinier antara variabel input dan output sampai mencapai akurasi tinggi. Model Artificial Neural Network telah diterapkan untuk memprediksi terjadinya hipertensi, disfungsi otonom kardiovaskular, penyakit arteri koroner, dan sindrom metabolik [12]. Berdasarkan penelitian terdahulu, model Artificial Neural Network dapat secara akurat memprediksi beragam keadaan klinis dan mengalahkan metode statistik konvensional [12]. Oleh karena itu, Artificial Neural Network dianggap cocok untuk memprediksi kondisi pasien dengan penyakit gagal jantung kongestif.

Terdapat penelitian terdahulu yang menjelaskan mengenai penggunaan sinyal short-term HRV untuk mendeteksi penyakit gagal jantung. Penelitian tersebut menggunakan ekstraksi fitur Matching Pursuit Algorithm untuk menganalisis sinyal HRV. Hasil ekstraksi fitur kemudian akan dijadikan input untuk klasifikasi menggunakan metode Genetic Algorithm dan K-Nearest Neighbour. Hasil dari klasifikasi tersebut adalah prediksi kondisi pasien dengan penyakit gagal jantung dan kondisi pasien sehat, namun penelitian ini tidak

dapat mengklasifikasikan penyakit gagal jantung berdasarkan kelasnya menurut New York Heart Association (kelas 1-4). Nilai akurasi yang didapatkan dari hasil klasifikasi adalah 95.65% [13]. Berdasarkan penelitian ini, dapat disimpulkan bahwa sinyal HRV dapat digunakan untuk memprediksi penyakit gagal jantung pada pasien.

Terdapat juga penelitian terdahulu yang membahas klasifikasi penyakit gagal jantung pada pasien menggunakan metode Artificial Neural Network berdasarkan ekstraksi fitur Multifractal Detrended Fluctuation Analysis pada sinyal HRV. Perbedaan antara penelitian tersebut dengan penelitian ini terdapat pada metode ekstraksi fiturnya yaitu Multifractal Detrended Fluctuation Analysis (MFdfa). Ekstraksi fitur MFdfa mengeluarkan output berupa nilai variabel jarak dan kelengkungan. Nilai variabel jarak dan kelengkungan tersebut akan dijadikan inputan pada klasifikasi menggunakan ANN. Hasil dari penelitian tersebut adalah pengklasifikasian pasien dengan kondisi penyakit gagal jantung dan pasien normal. Nilai akurasi yang didapatkan dari hasil akurasi adalah 67.24%. Dari hasil tersebut dapat disimpulkan bahwa ekstraksi fitur MFdfa tidak begitu baik digunakan untuk menjadi input ANN. Hal ini terjadi karena data biomedis memiliki struktur dan kompleksitas yang tinggi [14]. Oleh karena itu, pada penelitian ini akan digunakan metode ekstraksi fitur lain, yaitu Higher-Order Moments Detrended Fluctuation Analysis, untuk meningkatkan tingkat akurasi dari klasifikasi.

Tugas akhir ini akan membahas mengenai pengklasifikasian penyakit gagal jantung kongestif dengan menggunakan metode Artificial Neural Network berdasarkan hasil ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis pada sinyal HRV denyut jantung. Hasil dari tugas akhir ini adalah pengklasifikasian kondisi pasien dengan penyakit gagal jantung kongestif dan pasien normal. Dengan melakukan penelitian ini, diharapkan dapat membantu ahli medis dalam mendeteksi penyakit gagal jantung kongestif sehingga dapat mengurangi tingkat kematian karena penyakit tersebut.

## **1.2. Perumusan Masalah**

Perumusan masalah yang diangkat pada tugas akhir ini adalah:

1. Bagaimana hasil ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis pada sinyal HRV denyut jantung?
2. Bagaimana model klasifikasi pasien gagal jantung kongestif dengan Artificial Neural Network menggunakan fitur Higher-Order Moments Detrended Fluctuation Analysis?
3. Bagaimana hasil akurasi klasifikasi penyakit gagal jantung kongestif menggunakan Artificial Neural Network pada sinyal HRV denyut jantung yang sudah diekstraksi fiturnya menggunakan metode Higher-Order Moments Detrended Fluctuation Analysis?

## **1.3. Batasan Pengerjaan Tugas Akhir**

Batasan pemasalahan dalam tugas akhir ini adalah

1. Data yang digunakan adalah data sinyal ECG pada pasien penyakit gagal jantung kongestif dan pasien normal yang didapatkan dari [www.physionet.org](http://www.physionet.org) yang kemudian dikonversi menjadi sinyal HRV.
2. Data ECG yang digunakan adalah data 72 pasien normal dan 44 pasien penyakit gagal jantung kongestif.
3. Hasil dari penelitian ini merupakan implementasi metode Higher-Order Moments Detrended Fluctuation Analysis ke dalam MATLAB yang dapat digunakan untuk mengklasifikasikan data sinyal HRV dan model klasifikasi ANN.

## **1.4. Tujuan Tugas Akhir**

Tujuan dari tugas akhir ini adalah :

1. Untuk mengetahui struktur non-linear sinyal HRV denyut jantung pasien gagal jantung kongestif menggunakan hasil ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis.
2. Untuk mengetahui hasil klasifikasi penyakit gagal jantung kongestif menggunakan Artificial Neural Network pada sinyal HRV denyut jantung yang telah diekstraksi dengan menggunakan Higher-Order Moments Detrended Fluctuation Analysis.

### **1.5. Manfaat Tugas Akhir**

Manfaat yang diberikan dengan adanya tugas akhir ini adalah :

1. Manfaat bagi peneliti  
Menambah pengetahuan peneliti mengenai metode Higher-Order Moments Detrended Fluctuation Analisis untuk mengekstraksi fitur sinyal HRV pada pasien penyakit gagal jantung kongestif serta menambah pengetahuan mengenai pengklasifikasian penyakit gagal jantung kongestif menggunakan Artificial Neural Network.
2. Manfaat untuk instansi kesehatan / ahli medis  
Membantu instansi kesehatan atau ahli medis dalam mendiagnosa pasien terhadap penyakit gagal jantung kongestif sehingga segera dilakukan tindakan preventif dan memperkecil jumlah kematian penyakit gagal jantung kongestif akibat telatnya penanganan atau kesalahan diagnosa.
3. Manfaat untuk universitas  
Menambah referensi dalam penggunaan metode Higher-Order Moments Detrended Fluctuation Analysis dalam mengekstraksi fitur pada sinyal HRV serta menambah pengetahuan dalam pengklasifikasian prognosis menggunakan Artificial Neural Network

### **1.6. Relevansi**

Topik yang dibahas pada tugas akhir ini merupakan klasifikasi yang memiliki relevansi dengan bidang peminatan pada Laboratorium Rekayasa Data dan Intelektensi Bisnis. Topik ini berkaitan dengan mata kuliah Sistem Cerdas, Sistem Pendukung Keputusan, dan Statistika. Penelitian tentang penyakit gagal jantung kongestif ini perlu dilakukan klasifikasi karena penyakit gagal jantung kongestif merupakan penyakit mematikan dan memiliki jumlah korban yang sangat besar. Metode ekstraksi fitur yang digunakan pada penelitian ini yaitu Higher-Order Moments Detrended Fluctuation Analysis juga merupakan metode yang masih baru karena merupakan pengembangan dari metode Detrended Fluctuation Analysis [11] dan memiliki potensi besar untuk digunakan pada sinyal biomedis atau penyakit lainnya.

*(Halaman ini sengaja dikosongkan)*

## **BAB II**

### **TINJAUAN PUSTAKA**

Bab ini berisikan tinjauan pustaka yang akan digunakan dalam penelitian tugas akhir ini, mencakup studi sebelumnya, dasar teori dan metode yang digunakan.

#### **2.1. Studi Sebelumnya**

Dalam penggerjaan tugas akhir ini terdapat beberapa penelitian yang terkait untuk bisa dijadikan sebagai bahan studi literatur untuk menyelesaikan tugas akhir ini. Beberapa penelitian sebelumnya yang dijadikan acuan dalam penggerjaan tugas akhir disajikan dalam table-tabel berikut.

**Tabel 2.1 Studi Literatur1**

<b>Judul Paper</b>	Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Multifractal Detrended Fluctuation Analysis (MFDFA) Pada Variabilitas Denyut Jantung [14]
<b>Penulis; Tahun</b>	Dhimas Yoga Ananta; 2017
<b>Deskripsi Umum Penelitian</b>	Pada penelitian ini dilakukan penggunaan metode ekstraksi fitur Multifractal Detrended Fluctuation Analysis (MFDFA) pada sinyal Heart Rate Variability (HRV) untuk klasifikasi penyakit gagal jantung kongestif menggunakan metode Artificial Neural Network (ANN). Penelitian dilakukan pada data 72 pasien normal dan 44 pasien penyakit gagal jantung kongestif yang diambil dari <a href="http://www.Physionet.org">www.Physionet.org</a> . Hasil penelitian ini adalah klasifikasi pasien dengan kodisi penyakit gagal jantung dan pasien normal. Nilai akurasi yang

	didapatkan adalah 67.24% dengan hidden layer, momentum, dan learning rate yaitu 4, 0.5, dan 0.1.
<b>Keterkaitan Penelitian</b>	Penerapan ekstraksi fitur Multifractal Detrended Fluctuation Analysis pada sinyal HRV dan penggunaan metode klasifikasi Artificial Neural Network dapat menjadi referensi untuk metodologi yang akan digunakan pada tugas akhir.

**Tabel 2.2 Studi Literatur 2**

<b>Judul Paper</b>	Detrended fluctuation analysis based on Higher-Order moments of financial time series [11]
<b>Penulis; Tahun</b>	Yue Teng, Pengjian Shang; 2017
<b>Deskripsi Umum Penelitian</b>	Pada penelitian ini dilakukan metode Detrended Fluctuation Analysis (DFA) yang diperluas dengan menambahkan <i>skewness</i> dan <i>kurtosis</i> untuk menilai volatility scaling property pada data finansial time series. Data finansial yang digunakan adalah data pasar saham dari tiga negara di Amerika, tiga dari Cina, dan tiga dari Eropa. Hasil dari penelitian ini adalah detail higher moments volatility dan higher moments multiscale volatility yang tidak bisa didapatkan hanya dengan metode DFA traditional.
<b>Keterkaitan Penelitian</b>	Penerapan metode Higher-Order Moments Detrended Fluctuation Analysis dapat menjadi referensi untuk metodologi yang akan digunakan pada tugas akhir.

**Tabel 2.3 Studi Literatur 3**

<b>Judul Paper</b>	Comparison of Wavelet Transform Modulus Maxima and Multifractal Detrended Fluctuation Analysis of Heart Rate in Patients with Systolic Dysfunction of Left Ventricle [15]
<b>Penulis; Tahun</b>	Rafal Galaska, et al; 2008
<b>Deskripsi Umum Penelitian</b>	Pada penelitian ini dilakukan perbandingan antara metode Wavelet Transform Modulus Maxima (WTMM) dengan metode Multifractal Detrended Fluctuation Analysis (MFDFA) pada denyut jantung pasien dengan disfungsi sistolik ventrikel kiri. Penelitian ini dilakukan pada 90 pasien dengan fungsi sistolik ventrikel kiri yang menurun dan 39 pasien sehat. Lebar spektrum multifraktional dan eksponen Hurst dihitung dengan menggunakan metode WTMM dan M DFA dalam kurun waktu 5 jam di siang hari dan 5 jam di malam hari. Hasil penelitian menunjukkan bahwa metode MFDFA lebih sensitif dibandingkan dengan metode WTMM dalam diferensiasi variabilitas denyut jantung nonlinier antara pasien sehat dengan pasien sakit.
<b>Keterkaitan Penelitian</b>	Perbandingan antara metode Multifractal Detrended Fluctuation Analysis (MFDFA) dengan metode Wavelet Transform Modulus Maxima (WTMM) dapat dijadikan acuan untuk mengetahui metode apa yang lebih baik untuk menganalisa variabilitas denyut jantung yang bersifat nonlinier.

**Tabel 2.4 Studi Literatur 4**

<b>Judul Paper</b>	Multifractal Detrended Fluctuation Analysis of Human EEG: Preliminary Investigation and Comparison with the Wavelet Transform Modulus Maxima Technique [16]
<b>Penulis; Tahun</b>	Todd Zorick, Mark A. Mandelkern; 2013
<b>Deskripsi Umum Penelitian</b>	Pada penelitian ini dilakukan penggunaan metode Multifractal Detrended Fluctuation Analysis (MFdfa) dan metode Wavelet Transform Modulus Maxima (WTMM) pada sinyal electroencephalography (EEG). Penelitian dilakukan pada kondisi otak ketika bangun dan kondisi otak ketika tidur pada tahap yang berbeda. Hasil penelitian menunjukkan bahwa sinyal EEG lebih bagus dimodelkan dengan menggunakan metode MFdfa. Selain itu metode MFdfa lebih konsisten dan memiliki variansi yang lebih kecil untuk pengujian jarak pendek (<30 s) dibandingkan dengan metode WTMM yang sedikit lebih konsisten untuk pengujian jarak panjang (>8m).
<b>Keterkaitan Penelitian</b>	Penerapan metode Multifractal Detrended Fluctuation Analysis (MFdfa) dapat menjadi referensi untuk metodologi yang akan digunakan pada tugas akhir. Selain itu, perbandingan antara metode Multifractal Detrended Fluctuation Analysis (MFdfa) dengan metode Wavelet Transform Modulus Maxima (WTMM) dapat dijadikan acuan untuk mengetahui metode apa yang lebih baik digunakan pada tugas akhir.

**Tabel 2.5 Studi Literatur 5**

<b>Judul Paper</b>	Multifractal Detrended Fluctuation Analysis of Human Gait Diseases [17]
<b>Penulis; Tahun</b>	Srimonti Dutta, et al; 2013
<b>Deskripsi Umum Penelitian</b>	Pada penelitian ini dilakukan penggunaan metode Multifractal Detrended Fluctuation Analysis (MFDFA) pada data time-series pasien yang terkena penyakit gait. Penelitian dilakukan pada pasien sehat, pasien yang terkena penyakit Parkinson, dan pasien yang terkena penyakit Huntington. Hasil dari penelitian ini adalah tingkat multifractal terlihat lebih jelas pada pasien normal dibandingkan dengan pasien sakit. Hasil penelitian juga menunjukkan bahwa metode MFDFA dapat membedakan antara pasien sehat dan pasien sakit. Namun ketika membedakan antara pasien dengan penyakit Parkinson dan pasien dengan penyakit Huntington, metode MFDFA menunjukkan hasil nilai W yang mirip.
<b>Keterkaitan Penelitian</b>	Penerapan metode Multifractal Detrended Fluctuation Analysis (MFDFA) dapat menjadi referensi untuk metodologi yang akan digunakan pada tugas akhir.

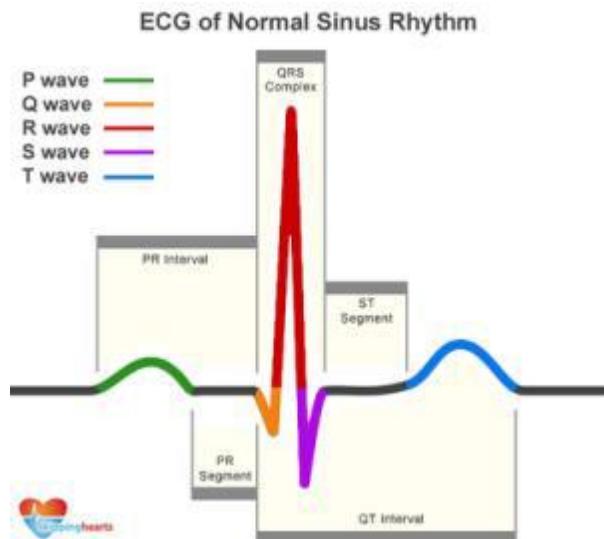
## 2.2. Dasar Teori

### 2.2.1. Penyakit Jantung

Penyakit jantung koroner atau penyakit kardiovaskular merupakan penyakit yang mempengaruhi jantung serta semua pembuluh darah di tubuh. Aterosklerosis merupakan salah satu penyakit kardiovaskular yang disebabkan oleh penumpukan plak di arteri seseorang. Penumpukan tersebut dapat terus terjadi sampai titik dimana penumpukan tersebut menyumbat arteri sepenuhnya sehingga berakibat pada terjadinya stroke atau serangan jantung. Serangan jantung dapat menyebabkan kerusakan permanen pada otot jantung [18]. Terdapat beberapa faktor risiko yang memiliki peran penting dalam timbulnya penyakit jantung koroner yaitu dari aspek metabolismik, hemostatis, imunologi, infeksi [19], hipertensi, hipercolesterolemia, dan merokok [20]. Faktor risiko lainnya adalah umur, ras, jenis kelamin, keturunan (bersifat irreversible), geografis, diet, obesitas, diabetes, olahraga, perilaku, stres, dan kebiasaan hidup lainnya [20].

### 2.2.2. Heart Rate Variability

*Heart Rate Variability* (HRV) adalah fenomena fisiologis dimana terjadi variasi interval waktu antar detak jantung [5]. HRV mencerminkan interaksi antara dua subsistem ANS (simpatik dan parasimpatik) yang selain mempengaruhi sistem organ lain, juga mempengaruhi sistem kardiovaskular. Penilaian HRV dilakukan dengan cara menganalisis rekam short-term dan long-term *Electrocardiogram* (ECG). Sinyal HRV didapatkan dengan mengitung nilai interval atau jarak antar gelombang R-R pada sinyal ECG [6]. Sedangkan ECG adalah rekam gelombang aktivitas kelistrikan jantung yang terdiri dari gelombang P, kompleks gelombang QRS, dan gelombang T. Hasil perekaman ECG menunjukkan karakteristik dari jantung [7]. Gambar 2.1 merupakan gelombang ECG pada manusia normal.



**Gambar 2.1 Gelombang ECG Normal**

HRV dapat digunakan untuk menentukan prognosis pada Coronary Heart Disease (CHD). Indikator prognosis yang paling sering digunakan adalah perhitungan standar deviasi dari nilai RR interval yang normal (SDNN) dan nilai HRV triangular index [6]. HRV triangular index adalah integral dari distribusi kepadatan (yaitu jumlah semua interval NN) dibagi dengan nilai maksimum distribusi kepadatan [21].

### 2.2.3. MATLAB

MATLAB (Matrix Laboratory) adalah suatu program analisis dan komputasi numerik dan merupakan suatu bahasa pemrograman matematika lanjutan yang dibentuk atas dasar pemikiran penggunaan sifat dan bentuk matriks. MATLAB merupakan sebuah lingkungan pemrograman canggih yang berisi fungsi-fungsi built-in untuk melakukan perhitungan matematis. Di dalam MATLAB terdapat toolbox yang berisi fungsi-fungsi tambahan untuk aplikasi khusus. MATLAB memiliki sifat extensible yang memungkinkan pengguna untuk

dapat menulis fungsi baru dan menambahkannya pada library ketika tidak ada fungsi built-in yang dapat melakukan tugas tersebut. MATLAB sering digunakan pada permasalahan yang melibatkan operasi matematika elemen, matrik, optimasi, aproksimasi, dan lain-lain [22].

#### 2.2.4. Klasifikasi

Klasifikasi adalah proses menemukan kesamaan yang ada pada satu set object dalam basis data dan mengklasifikasikannya ke dalam kelas yang berbeda-beda sesuai dengan model klasifikasi [23]. Klasifikasi data terdiri dari dua proses yaitu tahap pembelajaran (learning) dimana model klasifikasi dibuat dan tahap klasifikasi (classification) dimana model digunakan untuk memprediksi label kelas dari suatu data [24].

Terdapat dua jenis klasifikasi yaitu supervised dan unsupervised. Klasifikasi supervised adalah klasifikasi dimana label dari kelas sudah diketahui [25]. Sedangkan klasifikasi unsupervised adalah klasifikasi dimana data tidak memiliki label atau label tidak diketahui sehingga diperlukan pengelompokan data dengan nilai pengukuran yang mirip [26].

#### 2.2.5. Artificial Neural Network

*Artificial Neural Network* (ANN) adalah sebuah model yang terdiri dari node buatan yang saling terkoneksi dan memiliki karakteristik yang mirip seperti suatu jaringan syaraf biologis. ANN memiliki karakteristik yang ditiru dari jaringan syaraf biologis yaitu kemampuan belajar yang dimiliki manusia. Hal tersebut merupakan faktor utama yang membedakan ANN dengan sistem pakar (expert system). Expert system diprogram untuk membuat kesimpulan (inference) berdasarkan data atau pengetahuan dari lingkungan, sedangkan ANN dapat menyesuaikan bobot node sebagai tanggapan atas input dan mungkin pada output yang diinginkan. Berikut ini adalah kelebihan dari pemodelan ANN [27]:

1. Tidak memerlukan banyak asumsi, karena data dapat digunakan secara langsung (apa adanya).
2. Dapat memodelkan sistem secara non-linear dengan baik sehingga dapat digunakan secara fleksibel.
3. Mampu memberikan model yang mendekati sistem nyata.

Lapisan (layer) yang ada pada suatu jaringan dibedakan menjadi 3 macam, yaitu [27]:

1. Input Layer (Lapisan Masukan)

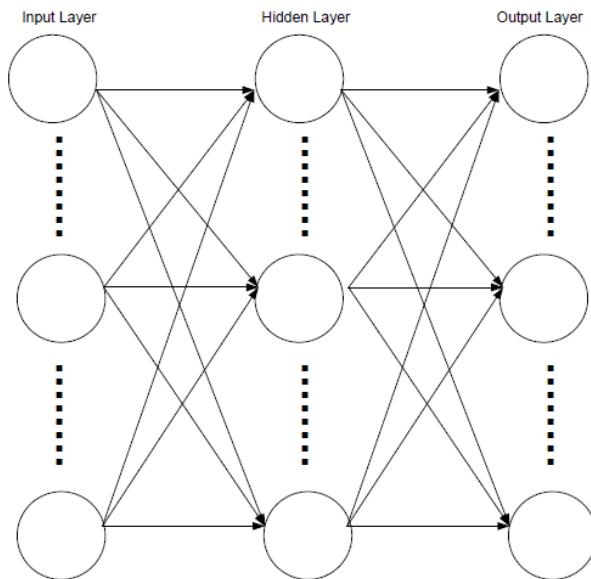
*Input layer* merupakan lapisan yang menerima masukan langsung dari lingkungan. Biasanya jumlah input layer disesuaikan dengan jumlah masukan.

2. Hidden Layer (Lapisan Tersembunyi)

*Hidden layer* merupakan lapisan yang berada di antara input layer dan output layer. Pada arsitektur ANN dengan 2 layer, maka tidak terdapat hidden layer. Banyaknya jumlah node yang digunakan pada hidden layer bervariasi, tergantung dari berdasarkan percobaan yang dilakukan beberapa kali untuk mendapat arsitektur terbaik. Masing-masing hidden layer akan ditambah dengan sebuah bias [28].

3. Output Layer (Lapisan Keluaran)

*Output layer* merupakan lapisan yang menghasilkan output akhir dari suatu jaringan ANN. Jumlah node pada layer ini disesuaikan dengan jumlah output yang diinginkan.



Gambar 2.2.2 Jaringan ANN Multilayer (Fauset, 1994)

### 2.2.6. Higher-Order Moments Detrended Fluctuation Analysis

Higher-Order Moments Detrended Fluctuation Analysis merupakan metode lanjutan dari Detrended Fluctuation Analysis (DFA), dimana terdapat perhitungan nilai *skewness* dan *kurtosis* untuk memeriksa volatilitas penskalaan properti (volatility scaling property). Metode ini menunjukan volatility behaviors dari time series dalam aspek-aspek yang berbeda [11]. Karena metode ini merupakan lanjutan dari metode DFA, maka metode ini juga sangat efektif dan efisien dalam menganalisis data non-linier dan non-stationer untuk mendapatkan estimasi kuantitatif dari stokastik yang ada pada data [29]. Berikut ini adalah langkah-langkah dalam penggunaan metode Higher-Order Moments DFA:

**Langkah 1:** Menghitung rata-rata  
Anggap  $x(i)$  untuk  $i=1 \dots N$  dengan rumus

$$\bar{x}_\text{ave} = \frac{1}{N} \sum_{i=1}^N x(i) \quad (1)$$

**Langkah 2:** Mengitung integrasi time series

$$y(i) = \sum_{k=1}^i [x(k) - \bar{x}_\text{ave}] \text{ for } i = 1 \dots N \quad (2)$$

**Langkah 3:** Membagi time series yang terintegrasi pada segment yang tidak saling overlapping  $N_s$  (dimana  $N_s = \text{int}(N/s)$ ) dan  $s$  adalah panjang segment. Karena panjang  $N$  bukan kelipatan  $s$ , sehingga untuk memasukan bagian ini pada rangkaian proses ini diulang dari kebalikannya. Sehingga  $2N_s$  segment didapat dan untuk setiap segment kita melakukan minimal square fit dari rangkaian tersebut dan menentukan variansinya.

a. *Skewness*

$$F_{SMDFA}^2(s, v) = \gamma \left( X_s^2(i) \right) = \frac{\langle X_s(i) - \langle X_s(i) \rangle \rangle^3}{[\sigma^2(X_s(i))]^{3/2}} \quad (3)$$

b. *Kurtosis*

$$F_{KMDFA}^2(s, v) = \kappa \left( X_s^2(i) \right) = \frac{\langle X_s(i) - \langle X_s(i) \rangle \rangle^4}{[\sigma^2(X_s(i))]^{3/2}} \quad (4)$$

Dari nilai detrended time series  $X_s(i)$  dengan membagi semua data poin  $i$  pada segment  $v$ th dimana

$$\begin{aligned} \langle X_s(i) \rangle &= \frac{1}{s} \sum_{i=1}^s X_s[(v-1)s+i], \quad v = 1, 2, \dots, N_s, \\ \langle X_s(i) \rangle &= \frac{1}{s} \sum_{i=1}^s X_s[N - (v - N_s)s + i], \quad v = N_s + 1, N_s + 2, \dots, 2N_s, \\ \sigma^2(X_s(i)) &= \langle X_s^2(i) \rangle - \langle X_s(i) \rangle^2, \end{aligned}$$

**Langkah 4:** Menghitung fungsi fluktuasi

Fungsi fluktuasi qth order didapatkan setelah merata-ratakan 2Ns segment.

$$F(s) = \left( \frac{1}{2Ns} \sum_{v=1}^{2Ns} [F^2(s, v)] \right)^{\frac{1}{2}} \quad (5)$$

**Langkah 5:** Menganalisa plot log-log dari nilai  $F(s)$  dengan untuk menentukan *scaling behavior* dari fungsi fluktuasi, dengan rumus:

$$F(s) \sim s^\alpha \quad (6)$$

Dimana  $\alpha$  adalah *scaling exponent* yang merepresentasikan sifat korelasi dari sinyal. Metode ini fokus pada variasi dari nilai *local scaling exponent* dari time series yang menjadi alat kuantitatif utama [11]. Untuk menentukan *scaling behavior* dari fungsi fluktuasi, dibutuhkan analisis nilai *local scaling exponent* yang dapat dihitung dengan rumus:

$$\alpha(s_k) = \frac{\log[F(s_{k+1})] - \log[F(s_{k-1})]}{\log[s_{k+1}] - \log[s_{k-1}]} \quad (7)$$

Dimana nilai  $s_k$  merupakan subset dari *scale* s.

### 2.2.7. Uji Rank Sum Wilcoxon

Uji wilcoxon rank sum test merupakan pengukuran yang digunakan untuk membandingkan distribusi pada sample data yang independen, sedangkan uji wolcoxon signed-rank test digunakan untuk membandingkan distribusi pada sample data yang dependen. Dalam uji Wilcoxon, nilai data untuk kedua sampel digabungkan dan kemudian diurutkan. Jika hipotesis nol benar, yang berarti bahwa tidak ada perbedaan dalam distribusi populasi, maka nilai dalam setiap sampel harus diberi peringkat kira-kira sama. Oleh karena itu, ketika peringkat setiap sample dijumlahkan, nilai jumlah harus kira-kira sama dan hipotesis nol tidak akan ditolak. Jika ada

perbedaan besar dalam penjumlahan peringkat, berarti distribusinya tidak sama dan hipotesis nol akan ditolak [30].

### 2.2.8. Uji Validitas

Uji validitas yang digunakan untuk memvalidasi hasil klasifikasi ANN adalah *Confusion Matrix* dan ROC (Receveir Operating Characteristic). Pengukuran *Confusion Matrix* yang biasa digunakan adalah *recall*, *precision*, dan *accuracy*. *Recall*, *precision* dan *accuracy* merupakan ukuran untuk mengetahui ketepatan (performa) prediksi dari suatu pengklasifikasi dengan lebih dari 2 (dua) kelas target (multikelas). Pada klasifikasi multikelas, akurasi hanya mengukur ketepatan pengklasifikasi pada seluruh kelas yang ada. Sedangkan *precision* dapat mengukur ketepatan prediksi pengklasifikasi pada kelas tertentu, dan *recall* dapat mengukur berapa banyak instans dari kelas tertentu yang dapat diprediksi secara benar. Perhitungan nilai *recall*, *precision* dan *accuracy* dapat dihitung berdasarkan rumus di bawah ini [31]:

$$\text{Recall (\%)} = \frac{\text{jumlah positif benar pada kelas tertentu}}{\text{jumlah total data aktual pada kelas tertentu}} \times 100\%$$

$$\text{Precision (\%)} = \frac{\text{jumlah positif benar pada kelas tertentu}}{\text{jumlah total data prediksi pada kelas tertentu}} \times 100\%$$

$$\text{Accuracy (\%)} = \frac{\text{jumlah positif benar} + \text{jumlah negatif benar}}{\text{jumlah total data}} \times 100\%$$

Sedangkan Receiver Operating Characteristic (ROC) digunakan untuk mengetahui tingkat sensitivity dan specificity dari klasifikasi. *Sensitivity* adalah proporsi jumlah positif benar yang diidentifikasi dengan benar. Sedangkan *specificity* adalah proporsi negatif benar yang diidentifikasi

dengan benar. Perhitungan *sensitivity* dan *specificity* dapat dihitung dengan menggunakan rumus di bawah ini [32]:

$$\text{Sensitivity (\%)} = \frac{\text{jumlah positif benar}}{\text{jumlah positif benar} + \text{jumlah negatif salah}} \times 100\%$$

$$\text{Specificity (\%)} = \frac{\text{jumlah negatif benar}}{\text{jumlah negatif benar} + \text{jumlah positif salah}} \times 100\%$$

Hasil nilai *Precision*, *Recall* dan Akurasi menunjukkan keakuratan hasil prediksi dari klasifikasi. Apabila nilai *Precision* dan *Recall* semakin mendekati 1, maka klasifikasi akan semakin akurat. Apabila nilai *Precision* dan *Recall* semakin mendekati 0, maka klasifikasi akan semakin tidak akurat. Begitu juga dengan nilai akurasi. Apabila nilai akurasi semakin mendekati 100%, maka klasifikasi akan semakin akurat. Sedangkan apabila nilai akurasi semakin mendekati 0%, maka klasifikasi semakin tidak akurat. Nilai ROC dapat menunjukkan bahwa klasifikasi tersebut dapat dikatakan sudah baik atau buruk. Kriteria keakuratan klasifikasi menggunakan ROC dapat dilihat dari Tabel 2.6 Kriteria Keakuratan Klasifikasi Menggunakan ROC Error! Reference source not found. [32].

Tabel 2.6 Kriteria Keakuratan Klasifikasi Menggunakan ROC

Nilai ROC	Interpretasi
0.90 – 1.00	Klasifikasi sangat baik
0.80 – 0.90	Klasifikasi baik
0.70 – 0.80	Klasifikasi cukup
0.60 – 0.70	Klasifikasi buruk
0.50 – 0.60	Klasifikasi salah

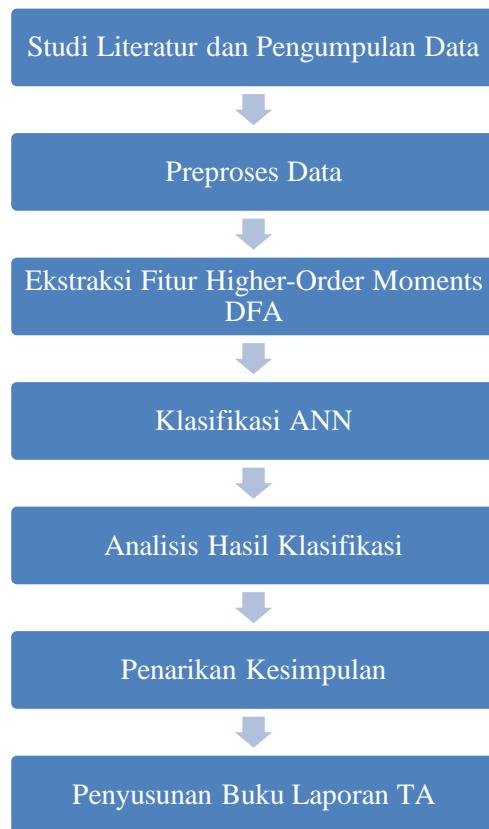
## BAB III

### METODOLOGI PENELITIAN

Pada bab ini menjelaskan terkait metodologi yang akan digunakan sebagai panduan untuk menyelesaikan penelitian tugas akhir ini.

#### 3.1. Metodologi Penelitian

Diagram Metodologi dari Tugas Akhir ini dapat dilihat pada Gambar 3.1 Metodologi Penelitian



Gambar 3.1 Metodologi Penelitian

### **3.2. Tahap Perancangan**

Berdasarkan pada diagram alur metodologi pada sub bab sebelumnya, di bawah ini merupakan penjelasan dari setiap prosesnya

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

Tahap ini merupakan tahapan pembelajaran terhadap topik yang diangkat untuk tugas akhir. Pembelajaran dapat dilakukan dengan cara mengumpulkan berbagai referensi seperti wawancara dengan narasumber, buku pustaka, penelitian sebelumnya, dan dokumen terkait. Pada tahap ini akan dilakukan pembelajaran mengenai metode Higher-Order Moments Detrended Fluctuation Analysis dengan melakukan review terhadap penelitian-penelitian terdahulu untuk dijadikan acuan. Selain itu, proses pengambilan data dilakukan melalui website Physionet.org. Data yang diambil berupa sinyal ECG pada pasien yang sehat dan yang sakit.

#### **3.2.2. Preproses Data**

Tahap ini merupakan tahap persiapan data yang akan digunakan untuk tugas akhir nanti. Pada tahap ini, data sinyal ECG yang diambil akan dikonversikan menjadi sinyal HRV dengan cara menghitung variasi R-R Interval-nya seperti yang dijelaskan pada sub-bab 2.2.2. Konversi dilakukan dengan menggunakan software Cygwin dan memasukan syntax yang dapat mengubah data sinyal ECG menjadi sinyal HRV. Hasil akhirnya adalah file baru berbasis csv yang memiliki 3 nilai yaitu detik keluarnya sinyal RR, nilai interval RR, dan status sinyal tersebut.

#### **3.2.3. Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis**

Pada tahap ini akan dilakukan aktivitas ekstraksi fitur menggunakan metode Higher-Order Moments Detrended Fluctuation Analysis. Data yang telah di-preproses yaitu data sinyal HRV selanjutnya akan dilakukan ekstraksi fitur menggunakan metode ekstraksi fitur *Higher-Order Moments*

*Dentrended Fluctuation Analysis.* Untuk melakukan ekstraksi fitur, *tools* yang digunakan adalah aplikasi MATLAB. Pada MATLAB, akan dibuat syntax yang dapat melakukan ekstraksi fitur menggunakan metode Higher-Order Moments Detrended Fluctuation Analysis. Input dari tahap ini adalah data sinyal ECG yang sudah dikonversikan menjadi sinyal HRV dengan cara menghitung variasi R-R Interval-nya. Output yang dihasilkan berupa nilai *skewness* dan *kurtosis* pada masing-masing data pasien normal dan pasien penyakit gagal jantung kongestif. Setelahnya, nilai *skewness* dan *kurtosis* tersebut akan dilakukan pengujian signifikansi data. Uji signifikansi juga dilakukan pada aplikasi MATLAB dengan menggunakan *syntax* untuk uji signifikansi. Kemudian hasil dari uji signifikansi akan dimasukan ke dalam struktur *Artificial Neural Network*.

### 3.2.4. Klasifikasi ANN

Tahap ini merupakan tahapan dimana data variabel *skewness* dan *kurtosis* yang sudah diuji signifikansi akan dimasukan ke dalam struktur *Artificial Neural Network*. Klasifikasi akan dilakukan dengan menggunakan fungsi *multilayer perceptron* pada aplikasi Weka. Input dari tahap ini adalah data variabel fungsi fluktuasi berdasarkan *kurtosis* yang sudah diuji signifikansi. Klasifikasi dilakukan dengan menggunakan *K-fold Cross Validation* sebanyak jumlah data input pada pasien sakit. Pada tahap ini akan dibuat model *Artificial Neural Network* yaitu jumlah *layer* dan *node* pada *hidden layer*, *momentum*, dan *learnin rate*. Output yang dihasilkan adalah hasil klasifikasi dari tiap percobaan *Higher-Order Moments Detrended Fluctuation Analysis* dan model terbaik dari parameter ANN yang diuji beserta hasil akurasinya.

Rencana Arsitektur Jaringan Syaraf Tiruan yang akan digunakan dalam tugas akhir terdiri dari input layer, hidden layer, dan output layer disertai dengan parameter yang digunakan dalam proses klasifikasi. Pada input layer bersisikan nilai fungsi fluktuasi berdasarkan *kurtosis*. Sedangkan pada hidden layer terdiri dari satu lapisan yang

berisi node dengan fungsi aktivasi sigmoid biner. Jumlah node pada hidden layer, penentuan learning rate, dan penentuan momentum dilakukan dengan menggunakan proses trial and error. Pada output layer berisi 3 node yang mengklasifikasikan penyakit jantung (level 3-4, level 1-3, dan normal).

### **3.2.5. Analisis Hasil Klasifikasi**

Setelah klasifikasi dilakukan, tahap selanjutnya adalah menganalisis hasil dari klasifikasi tersebut. Pada tahap ini akan dihitung tingkat akurasi dari klasifikasi serta dilakukan uji validitas menggunakan *Confusion Matrix* dan ROC seperti yang dijelaskan pada sub-bab 2.2.7 dan sub-bab 2.2.8.

### **3.2.6. Penarikan Kesimpulan**

Tahap ini merupakan tahapan dimana ditarik kesimpulan mengenai bagaimana penerapan metode Higher-Order Moments Detrended Fluctuation Analysis untuk mengekstraksi fitur pada sinyal HRV dan bagaimana hasil klasifikasi menggunakan metode Artificial Neural Network pada hasil ekstraksi fitur HRV.

### **3.2.7. Penyusunan Buku Laporan TA**

Tahapan terakhir adalah pembuatan laporan tugas akhir sebagai bentuk dokumentasi atas terlaksananya tugas akhir ini. Di dalam laporan tersebut mencakup :

**a. Bab I Pendahuluan**

Pada bab ini dijelaskan mengenai latar belakang, rumusan dan batasan masalah, tujuan dan manfaat penggerjaan tugas akhir ini.

**b. Bab II Tinjauan Pustaka**

Dijelaskan mengenai penelitian-penelitian serupa yang telah dilakukan serta teori – teori yang menunjang permasalahan yang dibahas pada tugas akhir ini.

**c. Bab III Metodologi Penelitian**

Pada bab ini dijelaskan mengenai tahapan – tahapan apa saja yang harus dilakukan dalam penggerjaan penelitian tugas akhir.

**d. Bab IV Perancangan**

Dalam bab ini dijelaskan mengenai bagaimana rancangan dari penilitan tugas akhir yang terdiri dari subjek dan objek penelitian, pemilihan subjek dan objek penelitian, dan bagaimana penelitian ini akan dilakukan.

**e. Bab V Implementasi**

Pada bab ini berisi proses pelaksanaan penelitian, bagaimana penelitian dilakukan, dan pembuatan model yang akan digunakan untuk klasifikasi.

**f. Bab VI Hasil dan Pembahasan**

Dalam bab ini dijelaskan mengenai pembahasan setelah melakukan implementasi.

**g. Bab VII Kesimpulan dan Saran**

Dalam bab ini dijelaskan mengenai kesimpulan dan saran yang ditujukan untuk kelengkapan penyempurnaan tugas akhir ini.

*(Halaman ini sengaja dikosongkan)*

## **BAB IV**

### **PERANCANGAN**

Pada bab ini akan dijelaskan bagaimana rancangan dari penelitian tugas akhir yang meliputi subyek dan obyek dari Tugas Akhir, pemilihan subyek dan obyek Tugas Akhir dan bagaimana Tugas Akhir akan dilakukan.

#### **4.1. Pengumpulan dan Pra-prosessing Data**

Pada bagian ini akan dilakukan pengambilan data dari sumber lalu kemudian mengelompokan data tersebut sesuai dengan tipe data. Data kemudian dilakukan proses pra-processing data agar dapat menghasilkan data yang siap dilakukan ekstraksi fitur.

##### **4.1.1. Pengumpulan Data**

Data yang digunakan untuk bahan penelitian tugas akhir ini adalah data sinyal ECG pada pasien normal dan pasien sakit Gagal Jantung Kongestif. Data diambil dari website Physionet.org yang merupakan dataset online. Jumlah data yang digunakan sebanyak 44 data sinyal ECG pasien Gagal Jantung Kongestif, yang terdiri dari 15 data chf1 yaitu penyakit chf untuk level 3-4 dan 29 data chf2 untuk penyakit chf level 1-3, dan 72 data sinyal ECG yang merupakan data nsr.

##### **4.1.2. Pra-processing data**

Tahap pra-processing data merupakan tahapan pengolahan data yang sudah dikumpulkan supaya dapat digunakan pada tahap selanjutnya. Data yang didapatkan masih berupa data sinyal ECG, sedangkan data yang dibutuhkan adalah data sinyal HRV. Oleh karena itu diperlukan konversi data sinyal ECG menjadi sinyal HRV dengan cara menghitung interval atau jarak antara gelombang R-R pada sinyal ECG.

## **4.2. Perancangan Model Higher-Order Moements Detrended Fluctuation Analysis**

Data yang telah diproses kemudian akan digunakan untuk melakukan perhitungan Higher Order Moments Detrended Fluctuation Analysis. Perhitungan Higher-Order Moments Detrended Fluctuation Analysis dilakukan dengan membuat perancangan model terlebih dahulu. Perancangan model Higher-Order Moments Detrended Fluctuation Analysis dilakukan dengan menentukan jumlah data dan menentukan nilai scale.

### **4.3. Menghitung Parameter Input**

Data yang sudah dihitung dengan menggunakan Higher-Order Moments Detrended Fluctuation Analysis akan dihitung parameter input yang akan digunakan dalam klasifikasi ANN yaitu parameter fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* dan parameter *local scaling exponent* berdasarkan *skewness* dan *kurtosis*.

#### **4.3.1. Menghitung Parameter Fungsi Fluktuasi berdasarkan *Skewness***

Hasil dari perhitungan Higher-Order Moments Detrended Fluctuation Analysis adalah nilai fungsi fluktuasi berdasarkan *skewness* dari masing-masing data pasien. Hasil parameter nilai fungsi fluktuasi berdasarkan *skewness* akan dilakukan uji signifikansi terlebih dahulu sebelum masuk ke dalam tahap klasifikasi.

#### **4.3.2. Menghitung Parameter Fungsi Fluktuasi berdasarkan *Kurtosis***

Hasil dari perhitungan Higher-Order Moments Detrended Fluctuation Analysis selanjutnya adalah nilai fungsi fluktuasi berdasarkan *kurtosis* dari masing-masing data pasien. Nilai parameter fungsi fluktuasi berdasarkan *kurtosis* akan dilakukan uji signifikansi sebelum masuk ke tahap klasifikasi selanjutnya.

#### **4.3.3. Menghitung Parameter *Local scaling exponent* berdasarkan *Kurtosis***

Hasil dari perhitungan Higher-Order Moments Detrended Fluctuation Analysis selanjutnya adalah nilai *local scaling exponent* berdasarkan *kurtosis* dari masing-masing data pasien. Nilai parameter *local scaling exponent* berdasarkan *kurtosis* akan dilakukan uji signifikansi sebelum masuk ke tahap klasifikasi selanjutnya.

#### **4.3.4. Menghitung Parameter *Local scaling exponent* berdasarkan *Kurtosis***

Hasil dari perhitungan Higher-Order Moments Detrended Fluctuation Analysis selanjutnya adalah nilai *local scaling exponent* berdasarkan *kurtosis* dari masing-masing data pasien. Nilai parameter *local scaling exponent* berdasarkan *kurtosis* akan dilakukan uji signifikansi sebelum masuk ke tahap klasifikasi selanjutnya.

### **4.4. Uji Signifikansi pada Parameter Input**

Parameter yang telah dihitung kemudian akan diuji signifikansi untuk mengetahui apakah antara parameter fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* dan parameter *local scaling exponent* berdasarkan *skewness* dan *kurtosis* untuk chf1, chf2, dan pasien normal ada perbedaan yang signifikan atau tidak. Output dari tahap ini adalah nilai parameter yang dinyatakan signifikan.

#### **4.4.1. Uji Signifikansi Fungsi Fluktuasi berdasarkan *Skewness***

Uji signifikansi untuk parameter fungsi fluktuasi berdasarkan *skewness* dilakukan dengan cara uji signifikansi Wilcoxon. Data pasien dibagi menjadi data chf1 yang merupakan data penyakit pasien Gagal Jantung Kongestif untuk level 3-4 dan data chf2 merupakan data pasien penyakit Gagal Jantung Kongestif untuk level 1-3, sedangkan data nsr merupakan data pasien normal. Data fungsi fluktuasi berdasarkan *skewness*

untuk masing-masing chf1 dan chf2 akan dilihat signifikansinya, kemudian data antara chf1 dengan nsr dan chf2 dengan nsr juga akan diuji signifikansinya.

#### **4.4.2. Uji Signifikansi Fungsi Fluktuasi berdasarkan Kurtosis**

Parameter fungsi fluktuasi berdasarkan *kurtosis* juga akan dilakukan uji signifikansi dengan menggunakan uji signifikansi Wilcoxon. Data pasien dibagi menjadi data chf1 yang merupakan data penyakit pasien Gagal Jantung Kongestif untuk level 3-4 dan data chf2 merupakan data pasien penyakit Gagal Jantung Kongestif untuk level 1-3, sedangkan data nsr merupakan data pasien normal. Kemudian semua data fungsi fluktuasi *kurtosis* untuk penyakit Gagal Jantung Kongestif dan normal akan dilihat signifikansinya antara chf1 dan chf2, kemudian akan dilihat juga signifikansi untuk masing-masing antara chf1 dengan nsr dan chf2 dengan nsr.

#### **4.4.3. Uji Signifikansi Local scaling exponent berdasarkan Skewness**

Uji signifikansi untuk parameter *local scaling exponent* berdasarkan *skewness* dilakukan dengan cara uji signifikansi Wilcoxon. Data pasien dibagi menjadi data chf1 yang merupakan data penyakit pasien Gagal Jantung Kongestif untuk level 3-4 dan data chf2 merupakan data pasien penyakit Gagal Jantung Kongestif untuk level 1-3, sedangkan data nsr merupakan data pasien normal. Data *local scaling exponent* berdasarkan *skewness* untuk masing-masing chf1 dan chf2 akan dilihat signifikansinya, kemudian data antara chf1 dengan nsr dan chf2 dengan nsr juga akan diuji signifikansinya.

#### **4.4.4. Uji Signifikansi Local scaling exponent berdasarkan Kurtosis**

Parameter *local scaling exponent* berdasarkan *kurtosis* juga akan dilakukan uji signifikansi dengan menggunakan uji signifikansi Wilcoxon. Data pasien dibagi menjadi data chf1

yang merupakan data penyakit pasien Gagal Jantung Kongestif untuk level 3-4 dan data chf2 merupakan data pasien penyakit Gagal Jantung Kongestif untuk level 1-3, sedangkan data nsr merupakan data pasien normal. Kemudian semua data *local scaling exponent* berdasarkan *kurtosis* untuk penyakit Gagal Jantung Kongestif dan normal akan dilihat signifikansinya antara chf1 dan chf2, kemudian akan dilihat juga signifikansi untuk masing-masing antara chf1 dengan nsr dan chf2 dengan nsr.

#### 4.5. Pemodelan ANN

Setelah melakukan uji signifikansi, hasil dari parameter yang dinyatakan signifikan akan dimasukan ke dalam model ANN. Untuk melakukan pemodelan ANN, diperlukan data yaitu total seluruh data yang signifikan dari hasil *Higher-Order Moments Detrended Fluctuation Analysis*. Data tersebut kemudian akan dilakukan *k-fold cross validation* baru kemudian dianalisis hasil klasifikasi dari data tersebut.

Data dibagi menjadi data training, data testing, dan data validasi dengan ratio yaitu 70:15:15. Data training akan diuji dengan data testing untuk mendapatkan model terbaik. Setelah mendapatkan model terbaik, barulah model tersebut diuji lagi dengan menggunakan data validasi.

Arsitektur ANN yang digunakan pada tugas akhir ini terdiri dari *input layer*, *hidden layer*, dan *output layer* yang disertai dengan parameter yang digunakan dalam proses klasifikasi. *Input layer* berisi nilai parameter yang dikatakan signifikan dari setiap data pasien, sedangkan pada *hidden layer* terdapat satu lapisan yang berisi node dengan fungsi aktivasi sigmoid biner.

Pemodelan ANN dilakukan dengan menentukan jumlah node pada *hidden layer*, menentukan *learning rate*, dan menentukan *momentum* dengan proses *trial and error*. Output layer berisi 3 node yaitu chf1 (chf level 3-4) untuk output node 1, chf2 (chf

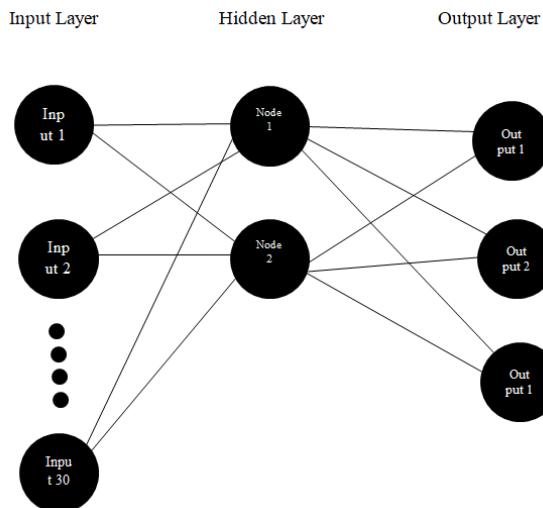
level 1-3) untuk output node 2 dan normal untuk output node 3.

**Tabel 4.1 Uji Model ANN**

Parameter	Jumlah	Deskripsi
Input Node	30	Nilai parameter yang dinyatakan lolos uji signifikansi
Hidden Layer Node	Trial and error	2-4 node 16 node 20 node
Output Layer Node	3 node	CHF1 (level 3-4) CHF2 (level 1-3) Dan Normal
Learning rate	Trial and error	0,1-0,9
Momentum	Trial and error	0,5-0,9
Epoch	Fix	3000

Tabel 4.1 Uji Model ANN menjelaskan mengenai perancangan model ANN yang akan digunakan pada tugas akhir ini beserta deskripsinya. Gambar 4.1 Struktur Model ANN merupakan contoh struktur model ANN dengan 1 *hidden layer* yang berisi 2 node, dimana pada input layer terdapat 30 input yaitu nilai parameter yang lolos uji signifikansi yang didapatkan dari ekstraksi fitur *Higher-Order Moments Detrended Fluctuation Analysis* dan kemudian akan diproses ke dalam algoritma ANN *feedforward*. Untuk menentukan jumlah *hidden layer*, *learning rate*, dan *momentum* digunakan teknik *trial and error*. Sedangkan untuk jumlah *hidden layer*, node yang digunakan adalah sebanyak 2-4 node, 16 node (70% atau 90% dari node pada *input layer*) [33], dan nilai hidden layer yang otomatis ditentukan oleh Weka yaitu 20. Rumus penentuan *hidden layer* yang dihasilkan otomatis dari Weka adalah jumlah attribut ditambah kelas dibagi 2. Sedangkan

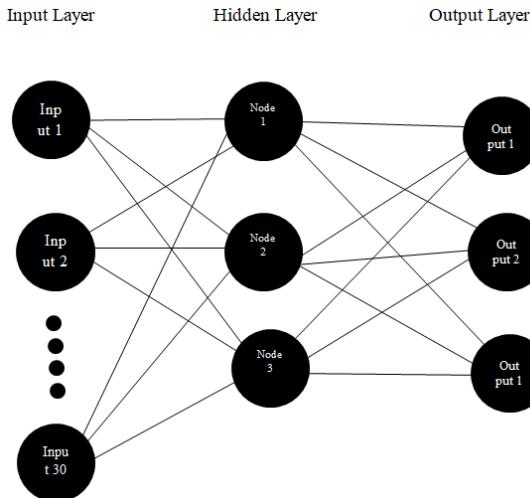
untuk *learning Rate* menggunakan nilai dari 0,1-0,9 dan untuk *momentum* menggunakan nilai dari 0,5-0,9. Output yang dihasilkan adalah 3 node yaitu chf1 untuk output node 1, chf2 untuk output node 2, dan normal untuk output node 3. Data akan dinyatakan sebagai chf1 jika pada output node 1 memiliki nilai 1, pada output node 2 memiliki nilai 0 dan pada output node 3 memiliki nilai 0. Data akan dinyatakan sebagai chf2 jika pada output node 1 memiliki nilai 0, pada output node 2 memiliki nilai 1 dan pada output node 3 memiliki nilai 0. Data akan dinyatakan sebagai nsr jika pada output node 1 memiliki nilai 0, pada output 2 memiliki nilai 0 dan pada output 3 memiliki nilai 1.



**Gambar 4.1 Struktur Model ANN untuk *Hidden Layer* Node Sejumlah 2**

Gambar 4.2 Struktur Model ANN untuk *Hidden Layer* Node Sejumlah 3 merupakan contoh struktur model ANN dengan 1 hidden layer yang berisi 3 node, dimana pada input layer terdapat 30 input yaitu nilai parameter yang lolos uji signifikansi yang didapatkan dari ekstraksi fitur *Higher-Order Moments Detrended Fluctuation Analysis* dan 3 output node

berupa CHF1 untuk output node 1, CHF2 untuk output node 2, NSR untuk output node 3.

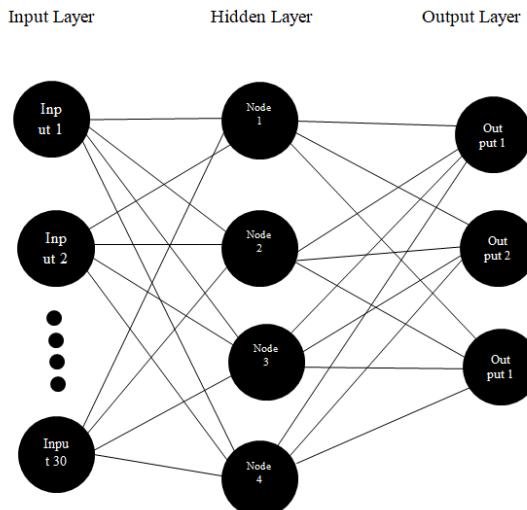


Gambar 4.2 Struktur Model ANN untuk *Hidden Layer* Node Sejumlah 3

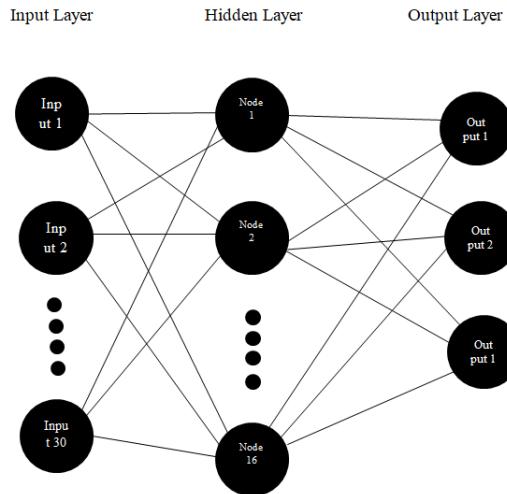
Gambar 4.3 Struktur Model ANN untuk *Hidden Layer* Node Sejumlah 4 merupakan contoh struktur model ANN dengan 1 hidden layer yang berisi 4 node, dimana pada input layer terdapat 30 input yaitu nilai parameter yang lolos uji signifikansi yang didapatkan dari ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis dan 3 output node berupa CHF1 untuk output node 1, CHF2 untuk output node 2, NSR untuk output node 3.

Gambar 4.4 Struktur Model ANN untuk *Hidden Layer* Node Sejumlah 16 merupakan contoh struktur model ANN dengan 1 hidden layer yang berisi 16 node, dimana pada input layer terdapat 30 input yaitu nilai parameter yang lolos uji signifikansi yang didapatkan dari ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis dan 3 output node berupa CHF1 untuk output node 1, CHF2 untuk output node 2, NSR untuk output node 3.

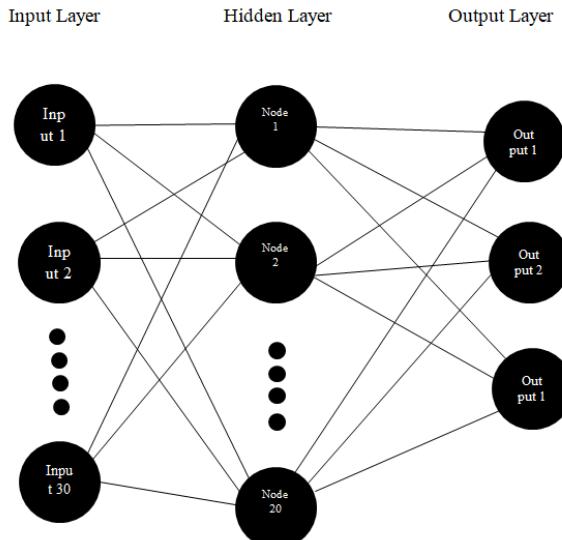
Gambar 4.5 Struktur Model ANN untuk *Hidden Layer Node* Sejumlah 20 merupakan contoh struktur model ANN dengan 1 hidden layer yang berisi 20 node, dimana pada input layer terdapat 30 input yaitu nilai parameter yang lolos uji signifikansi yang didapatkan dari ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis dan 3 output node berupa CHF1 untuk output node 1, CHF2 untuk output node 2, NSR untuk output node 3.



Gambar 4.3 Struktur Model ANN untuk *Hidden Layer Node* Sejumlah 4



Gambar 4.4 Struktur Model ANN untuk *Hidden Layer* Node Sejumlah 16



Gambar 4.5 Struktur Model ANN untuk *Hidden Layer* Node Sejumlah 20

#### 4.6. Uji Validitas

Hasil klasifikasi ANN dengan parameter kemudian akan diuji validitasnya menggunakan *Confusion Matrix* berupa *Precision*, *Recall*, dan *Accuracy*. Selain itu, akan dilakukan juga uji validitas dengan menggunakan ROC untuk mengetahui apakah hasil klasifikasi tersebut baik atau buruk.

## BAB V

### IMPLEMENTASI

Bab ini berisi mengenai penjelasan proses pelaksanaan penelitian dan pembuatan model yang akan digunakan untuk klasifikasi.

#### 5.1. Pra Processing Data

Data yang telah dikumpulkan harus dikonversi terlebih dahulu ke dalam HRV. Untuk melakukan konversi dari sinyal ECG ke HRV dapat menggunakan software Cygwin. *Syntax* yang digunakan pada Cygwin untuk mengubah data sinyal ECG menjadi data sinyal HRV adalah `rrlist ecg filename -s >fileoutput.rr`. *Syntax* tersebut akan menghasilkan file baru berbasis .rr dengan 3 nilai, yaitu nilai detik keluarnya sinyal R-R, nilai interval R-R, dan status dari sinyal tersebut. Tabel 5.1 merupakan contoh dari hasil output pra proses data ECG ke HRV.

Tabel 5.1 Pra Proses Data ECG ke HRV

Detik ke-	Interval R-R	Status
0.896	0.784	N
1.752	0.856	N
2.612	0.86	N
...	...	...
71977.448	1.056	N

Karena nilai status tidak diperlukan pada penelitian ini, maka nilai status akan dihapus. Selanjutnya setelah semua nilai status dihapus, maka data siap digunakan untuk perhitungan model Higher-Order Moments Detrended Fluctuation Analysis

## 5.2. Penyiapan Data Masukan

Data yang sudah siap digunakan untuk implementasi Higher-Order Moments Detrended Fluctuation Analysis akan dimasukan ke dalam aplikasi MATLAB. Karena data yang ada masih dalam format .rr dan matlab tidak dapat langsung memproses data rr, maka diperlukan *syntax* untuk membaca format rr yaitu ‘dlmread’. Data yang telah diproses dengan menggunakan dlmread kemudian akan menjadi variabel baru yang dapat digunakan pada MATLAB.

## 5.3. Membagi Data

Setelah data dimasukan ke dalam MATLAB, data akan dibagi menjadi dua, yaitu data dengan panjang data 15 menit dan dengan panjang data 20 menit. Pembagian data ini dilakukan untuk uji coba *Higher-Order Moments Detrended Fluctuation Analysis* agar mengetahui perbedaan hasil dari panjang data yang berbeda. *Syntax* yang digunakan untuk membagi data menjadi 20 menit dapat dilakukan seperti pada Segmen Program 5.1.

Baris pertama Segmen Program 5.1 menjelaskan mengenai dimulainya iterasi untuk membagi data menjadi 20 menit. Iterasi dilakukan sebanyak jumlah input file, yaitu sebanyak jumlah data yang ada. Lalu data tersebut dimasukan ke dalam MATLAB dengan *syntax* dlmread. Jumlah merupakan array yang menyimpan selisih dari keseluruhan data dengan data pertama. Jadi, data detik kedua akan dikurangi oleh data detik pertama. Lalu data detik ketiga akan dikurangi dengan data detik pertama. Hal ini dilakukan terus menerus sampai semua data telah dikurangi oleh data detik pertama. Variable hitung memiliki nilai yang sama dengan variable jumlah. Kemudian variabel a akan mencari nilai hitung yang kurang dari 1200 detik. Hal ini berarti variable a akan mencari data yang

```

for i=1:size(inputfile)
    data = dlmread([inputfile(i,:) '.rr']);
    jumlah = data(:,1)-data(1,1);
    hitung = jumlah(:,1);
    a = find(hitung<1200);
        dataA = data(1:a(end),2);
    b = find(hitung<2400);
        dataB = data(a(end)+1:(b(end)),2);
    c = find(hitung<3600);
        dataC = data(b(end)+1:(c(end)),2);
    ...
    bt = find(hitung<86400);
        dataBT = data(bs(end)+1:(bt(end)),2);
    bu = find(hitung<87600);
        dataBU = data(bt(end)+1:(bu(end)),2);
end
save('chf001_20m_01.mat', 'dataA');
save('chf001_20m_02.mat', 'dataB');
save('chf001_20m_03.mat', 'dataC');
...
save('nsr072_20m_72.mat', 'dataBT');
save('nsr072_20m_73.mat', 'dataBU');

```

### Segmen Program 5.1

memiliki interval antara data tersebut dengan data pertama yaitu kurang dari 1200 detik (20 menit). Jika sudah didapatkan, maka variabel a akan disimpan pada dataA. Untuk mencari data 20 menit selanjutnya, variable b akan mencari data yang memiliki interval antara data tersebut dengan data pertama yaitu kurang dari 2400. Setelah mendapatkan data tersebut, maka dataB akan menyimpan data a yang paling terakhir lalu ditambah 1 sampai dengan data b yang terakhir. Lakukan hal yang sama untuk semua data sampai semua data telah terbagi menjadi 20 menit. Kemudian, simpan data tersebut menjadi variabel baru seperti yang ada pada baris 16 sampai 20. Hal yang sama juga dilakukan ketika

akan membagi data menjadi 15 menit, perbedaannya hanyalah pada interval data yang dimasukan yaitu 900 detik.

#### **5.4. Implementasi Higher-Order Moments Detrended Fluctuation Analysis**

Data yang sudah diproses dengan menggunakan syntax dlmread kemudian akan dilakukan implementasi menggunakan Higher-Order Moments Detrended Fluctuation Analysis pada MATLAB. Segmen Program 5.3 adalah *syntax* keseluruhan dalam perhitungan model Higher-Order Moments Detrended Fluctuation Analysis.

##### **5.4.1. Menghitung Integrasi Time Series**

Langkah awal pada implementasi Higher-Order Moments Detrended Fluctuation Analysis adalah mengubah *noise like time series* menjadi sebuah *random walk time series*. Pada MATLAB, pengubahan *noise like time series* dapat dilakukan dengan memasukan *syntax* seperti Segmen Program 5.2.

```
X=cumsum(input-mean(input));
```

##### **Segmen Program 5.2**

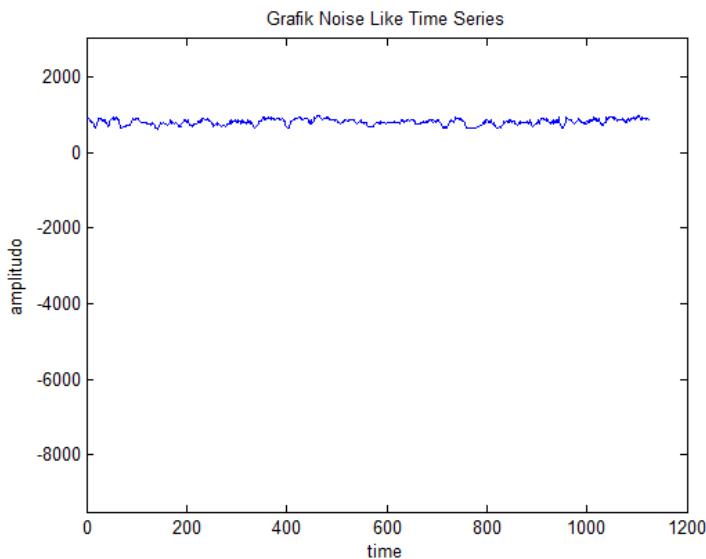
Untuk mengubah *noise like time series* menjadi *random walk time series*, dilakukan perhitungan rata-rata time series, lalu untuk tiap data akan dikurangi oleh rata-rata tersebut dan dilakukan penjumlahan kumulatif.

```

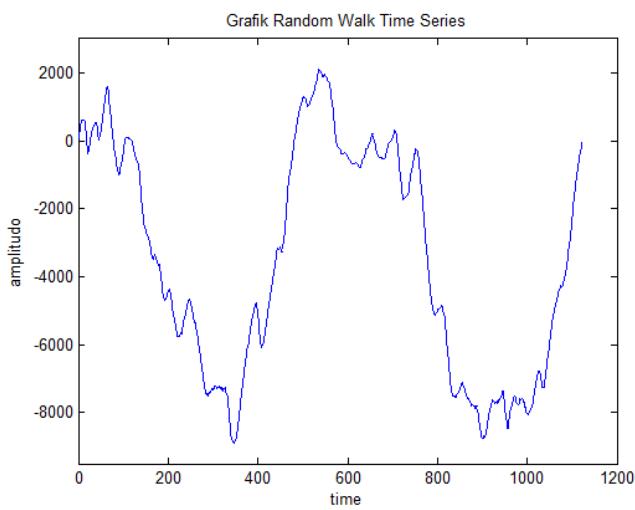
function [Parameter1,Parameter2,Parameter3,Parameter4]
    = higherorderdfafix(input)
X=cumsum(input-mean(input));
X=transpose(X);
jumlahTitik = 30;
logs = zeros(jumlahTitik,1);
logs(1,1) = log10(5);
N = 900;
range = log10(900)-logs(1,1);
tick = range/jumlahTitik;
for i = 2:jumlahTitik,
    logs(i,1) = logs(i-1,1)+tick;
end
scale = ceil(10.^logs);
m=1;
skewness=[];
kurtosis=[];
alphaRMSgabung=[];
alphaRMS_2gabung=[];
for ns=1:length(scale),
    segments(ns)=floor(length(X)/scale(ns));
    for v=1:segments(ns),
        Index=(((v-1)*scale(ns))+1):(v*scale(ns));
        C=polyfit(Index,X(Index),m);
        fit=polyval(C,Index);
        Xsi_1=(X(Index)- fit);
        meanXsi = mean(Xsi_1);
        var = mean(Xsi_1.^2)-meanXsi.^2;
        skewness(v) = mean((Xsi_1 - (meanXsi)).^3
        ./ var.^3/2);
        kurtosis(v) = mean((Xsi_1 - (meanXsi)).^4
        ./ var.^2);
    end
    RMS(ns)=sqrt(mean(skewness));
    RMS_2(ns)=sqrt(mean(kurtosis));
end
for j=2:(length(scale)-1),
    alphaRMS(j)=log(RMS(j+1))-log(RMS(j-1));
    alphaRMSScale(j)=log(scale(j+1))-log(scale(j-1));
    alphaRMSgabung=alphaRMS./alphaRMSScale;
    alphaRMS_2(j)=log(RMS_2(j+1))-log(RMS_2(j-1));
    alphaRMS_2Scale(j)=log(scale(j+1))-log(scale(j-1));
    alphaRMS_2gabung=alphaRMS_2./alphaRMS_2Scale;
end
Parameter1=RMS;
Parameter2=RMS_2;
Parameter3=alphaRMSgabung;
Parameter4=alphaRMS_2gabung;
end

```

### Segmen Program 5.3



**Gambar 5.1 Noise Like Time Series**



**Gambar 5.2 Random Walk Time Series**

Gambar 5.1 Noise Like Time Series dan Gambar 5.2 Random Walk Time Series merupakan contoh dari *noise like time series* dan *random walk time series*.

#### 5.4.2. Membagi Segment

Tahap selanjutnya pada metode Higher-Order Moments Detrended Fluctuation Analysis adalah membagi *random walk time series* tadi menjadi beberapa segmen/bagian. Nilai segment/bagian merupakan merupakan panjang dari data dibagi dengan nilai *scale*. Tiap segmen/bagian tersebut akan dicari *trend*-nya dengan cara melakukan *fitting polynomial*. Setelah ditemukan *trend*-nya, maka akan dicari luas dari tiap segmen dengan garis *trend* yang muncul dan dilakukan penjumlahan. Cara ini dilakukan sebanyak jumlah segmen/bagian yang dimasukan ke dalam MATLAB. Untuk mendapatkan nilai *scale* dapat menggunakan *syntax* seperti Segmen Program 5.4.

```
jumlahTitik = 30;
logs = zeros(jumlahTitik,1);
logs(1,1) = log10(5);
N = 900;
range = log10(900)-logs(1,1);
tick = range/jumlahTitik;
for i = 2:jumlahTitik,
    logs(i,1) = logs(i-1,1)+tick;
end
scale = ceil(10.^logs);
```

**Segmen Program 5.4**

Untuk membagi random walk time series tadi menjadi beberapa segmen/bagian dapat menggunakan *syntax* seperti pada Segmen Program 5.5.

```
for ns=1:length(scale),
    segments(ns)=floor(length(X)/scale(ns));
;
```

#### Segmen Program 5.5

### 5.4.3. Menghitung Fungsi Fluktuasi berdasarkan *Skewness* dan *Kurtosis*

Setelah data dibagi per-segment/bagian, langkah selanjutnya adalah menghitung nilai fungsi fluktuasi dari tiap segment/bagian. Terdapat dua hasil nilai fungsi fluktuasi, yaitu fungsi fluktuasi berdasarkan nilai *skewness* dan fungsi fluktuasi berdasarkan nilai *kurtosis*. Nilai *skewness* dan *kurtosis* dapat dicari dengan menggunakan *syntax* seperti Segmen Program 5.6.

```
for v=1:segments(ns),
    Index=(((v-1)*scale(ns))+1):(v*scale(ns));
    C=polyfit(Index,X(Index),m);
    fit=polyval(C,Index);
    Xsi_1=(X(Index)- fit);
    meanXsi = mean(Xsi_1);
    var = mean(Xsi_1.^2)-meanXsi.^2;
    skewness(v) = mean((Xsi_1 -
        (meanXsi))).^3 ./ var.^(3/2);
    kurtosis(v) = mean((Xsi_1 -
        (meanXsi))).^4 ./ var.^2;
end
```

#### Segmen Program 5.6

Setelah menemukan nilai *skewness* dan *kurtosis*, selanjutnya hitung nilai fungsi fluktuasi dengan menggunakan *syntax* seperti Segmen Program 5.7.

```
RMS(ns)=sqrt(mean(skewness));
RMS_2(ns)=sqrt(mean(kurtosis));
```

#### Segmen Program 5.7

Variabel RMS merupakan hasil dari nilai fungsi fluktuasi berdasarkan *skewness*, sedangkan variabel RMS\_2 merupakan hasil dari nilai fungsi fluktuasi berdasarkan *kurtosis*.

Hasil fungsi fluktuasi ini selanjutnya akan dilakukan perhitungan logaritma. Kemudian nilai fungsi fluktuasi tersebut akan di-plot dengan log segment. Perhitungan logaritma dapat dilakukan dengan menggunakan *syntax* seperti Segmen Program 5.8.

```
plot(log10(scale),log10(RMS)', 'o-r');
plot(log10(scale),log10(RMS_2)', 'o-r');
```

**Segmen Program 5.8**

#### 5.4.4. Menghitung Nilai *Local Scaling Exponent* berdasarkan *Skewness* dan *Kurtosis*

Setelah mendapatkan nilai fungsi fluktuasi berdasarkan *skewness* dan *kurtosis*, kedua nilai tersebut akan digunakan untuk menghitung nilai *local scaling exponent* berdasarkan *skewness* dan *kurtosis*. Untuk melakukan hal tersebut, dapat dilakukan dengan *syntax* seperti Segmen Program 5.10.

```
for j=2:(length(scale)-1),
alphaRMS(j)=log(RMS(j+1))-log(RMS(j-1));
alphaRMSScale(j)=log(scale(j+1))-log(scale(j-1));
alphaRMSgabung=alphaRMS./alphaRMSScale;

alphaRMS_2(j)=log(RMS_2(j+1))-log(RMS_2(j-1));
alphaRMS_2scale(j)=log(scale(j+1))-log(scale(j-1));
alphaRMS_2gabung=alphaRMS_2./alphaRMS_2scale;
end
```

**Segmen Program 5.9**

Variabel alphaRMSgabung merupakan hasil dari nilai *local scaling exponent* berdasarkan *skewness*, sedangkan variabel alphaRMS\_2gabung merupakan hasil dari nilai *local scaling exponent* berdasarkan *kurtosis*.

Hasil *local scaling exponent* ini selanjutnya akan dilakukan perhitungan logaritma. Kemudian nilai fungsi fluktuasi tersebut akan di-plot dengan log segment. Perhitungan logaritma dapat

dilakukan dengan menggunakan syntax seperti Segmen Program 5.10.

```
plot(log10(scale(1:length(scale)-1)),
     alphaRMSgabung, 'o-r');
plot(log10(scale(1:length(scale)-1)),
     alphaRMS_2gabung, 'o-r');
```

**Segmen Program 5.10**

#### 5.4.5. Menghitung Parameter Input

Hasil dari nilai fungsi fluktuasi dan nilai *local scaling exponent* kemudian akan dilakukan perhitungan parameter. Parameter yang digunakan adalah nilai fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* dan nilai *local scaling exponent* berdasarkan *skewness* dan *kurtosis*. Kedua nilai tersebut sudah didapatkan pada sub-bab 5.3.3 dan sub-bab 5.3.4. Perhitungan tersebut dapat dilakukan dengan menggunakan *syntax* seperti pada Segmen Program 5.11.

```
Parameter1=RMS;
Parameter2=RMS_2;
Parameter3=alphaRMSgabung;
Parameter4=alphaRMS_2gabung;
```

**Segmen Program 5.11**

#### 5.5. Uji Coba Model Higher-Order Moments Detrended Fluctuation Analysis

Uji coba Higher-Order Moments Detrended Fluctuation Analysis dilakukan untuk mendapatkan signifikansi yang baik dan akan digunakan selanjutnya pada proses klasifikasi. Uji coba model *Higher-Order Detrended Fluctuation Analysis* dilakukan dengan mengganti jumlah data menjadi 15 menit dan 20 menit.

**Tabel 5.2 Uji Coba MFdfa**

Percobaan	Jumlah Data
1.	15 menit

2.

20 menit

## 5.6. Uji Signifikansi Parameter

Setelah didapatkan hasil ekstraksi fitur yaitu fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* dan *local scaling exponent* berdasarkan *skewness* dan *kurtosis*, maka akan dilakukan uji signifikansi dengan menggunakan *Wilcoxon rank sum test*. Hasil parameter tersebut akan dilihat signifikansinya antara pasien gagal jantung kongestif level 3-4 (chf1) dengan pasien gagal jantung kongestif level 1-3 (chf2), signifikansi antara chf1 dengan pasien normal (nsr) dan signifikansi antara chf2 dengan nsr. Sebelum melakukan uji signifikansi, data harus dibersihkan terlebih dahulu dengan cara menghilangkan nilai NaN. Setelah menghilangkan nilai NaN pada masing-masing parameter, berulah dilakukan pencarian nilai *p-value*. Karena nilai fungsi fluktuasi dan *local scaling exponent* dihitung per titik yang ada pada data chf1, chf2, dan nsr, maka hasil uji signifikansi dari masing-masing hasil ekstraksi fitur adalah sejumlah 30 nilai. Kemudian akan dicari rata-rata dari nilai *p-value* uji signifikansi tersebut. *Syntax* yang digunakan untuk menjalankan uji signifikansi adalah seperti pada Segmen Program 5.12 .

```

sig_chf1_chf2_1_o1 = ranksum(chf1_o1_1,
                                chf2_o1_1);
sig_chf1_chf2_2_o1 = ranksum(chf1_o1_2,
                                chf2_o1_2);
...

```

**Segmen Program 5.12**

Dimana sig\_chf1\_chf2\_1\_o1 merupakan hasil uji signifikansi antara data chf1 dan chf2 untuk fungsi fluktuasi berdasarkan *skewness* pada titik 1. Sedangkan chf1\_o1\_1 merupakan nilai fungsi fluktuasi berdasarkan *skewness* untuk chf1 pada titik pertama dan chf2\_o1\_1 adalah nilai fungsi fluktuasi berdasarkan *skewness* untuk chf2 pada titik kedua. Fungsi

ranksum adalah fungsi *built-in* yang ada pada MATLAB untuk menghitung uji signifikansi menggunakan *Wilcoxon rank sum test*. Ulangi kode program tersebut sampai menemukan semua nilai uji signifikansi dari masing-masing titik untuk data chf1, chf2, dan nsr. Baru setelahnya dicari rata-rata dari nilai *p-value* uji signifikansi dari masing-masing data chf1, chf2., dan nsr.

Hasil uji signifikansi tersebut kemudian akan dilihat apakah termasuk baik atau tidak. Nilai ekstraksi fitur dikatakan lulus uji signifikansi jika nilai *p-value*-nya melebihi 0.05 ( $p-value < 0.05$ ). Jika rata-rata nilai *p-value* uji signifikansi kurang dari 0.05, maka hasil ekstraksi fitur tersebut dinyatakan signifikan. Semakin baik hasil uji signifikansi, maka akan semakin bagus pula hasil klasifikasinya.

## 5.7. Implementasi Klasifikasi Artificial Neural Network

Parameter output *Higher-Order Moments Detrended Fluctuation Analysis* yang signifikan selanjutnya dilakukan uji klasifikasi dengan menggunakan ANN. Data yang sudah siap diuji akan diolah menggunakan aplikasi Weka untuk melakukan klasifikasi. Fungsi yang digunakan pada Weka adalah *multilayer perceptron*.

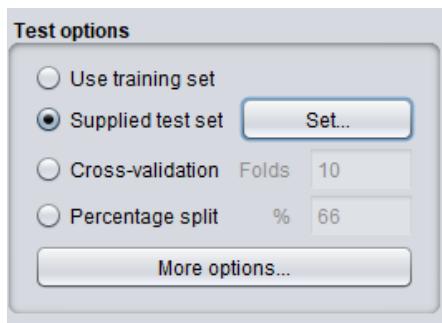
### 5.7.1. Pemrosesan Data

Sebelum melakukan klasifikasi, data akan dibagi menjadi data training, data testing, dan data validasi dengan ratio yaitu 70:15:15. Untuk data dengan panjang data 15 menit, jumlah data training adalah 6654, jumlah data testing adalah 1425 dan jumlah data validasi adalah 1425. Untuk data dengan panjang data 20 menit, jumlah data training adalah 4901, jumlah data testing adalah 1050 dan jumlah data validasi adalah 1050.

Data output dari *Higher-Order Moments Detrended Fluctuation Analysis* akan dimasukan ke dalam Ms.Excel lalu kemudian diubah menjadi file .csv. Setelah itu, file .csv tersebut akan diubah menjadi file .arff baru kemudia di proses pada Weka untuk dilakukan klasifikasi.

### 5.7.2. Uji Klasifikasi ANN

Pada uji klasifikasi, data yang sudah dibagi menjadi data training dan data testing akan diuji satu sama lain untuk mendapatkan model terbaik. Pengujian ini dilakukan untuk melatih sebuah model hingga mendapatkan hasil yang paling baik. Fungsi yang digunakan pada Weka untuk menjalankan proses tersebut adalah *Supplied test set* lalu kemudian memasukan data *testing* sebagai inputannya. Fungsi tersebut dapat dipilih pada menu Test Option seperti pada Gambar 5.3 Menu Test Option pada Weka.



Gambar 5.3 Menu Test Option pada Weka

Pemilihan model terbaik dilakukan dengan cara uji coba terhadap *node hidden layer*, *learning rate*, *momentum*, dan *epoch*. Hasil keluaran akan berbeda-beda untuk tiap uji coba dan akan dipilih performa terbaik dan dilihat berdasarkan parameter *correctly classified instances* yang paling besar. Parameter ANN yang digunakan dirangkum pada Tabel 4.1 **Uji Model ANNError! Reference source not found..**

### 5.8. Uji Validitas Klasifikasi

Setelah mendapatkan model ANN yang terbaik, barulah model tersebut diuji dengan menggunakan data validasi. Fungsi yang digunakan pada weka adalah *Supplied test set* seperti pada Gambar 5.3 Menu Test Option pada Weka. Setelah dilakukan klasifikasi, akan muncul *confusion matrix* berupa *Precision*,

*Recall*, *Accuracy*, dan *ROC*. Nilai tersebut akan menentukan apakah klasifikasi termasuk baik atau tidak. Contoh dari hasil klasifikasi dapat dilihat pada Gambar 5.4 Contoh Hasil Klasifikasi ANN.

```
==== Summary ====
Correctly Classified Instances      959          67.2982 %
Incorrectly Classified Instances   466          32.7018 %
Kappa statistic                   0.036
Mean absolute error               0.2286
Root mean squared error          0.4101
Relative absolute error           69.3315 %
Root relative squared error     101.0334 %
Total Number of Instances        1425

==== Detailed Accuracy By Class ====
          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC    ROC Area  PRC Area  Class
          0.024    0.004    0.444     0.024   0.045    0.080   0.692    0.280    CHF1
          0.020    0.005    0.500     0.020   0.038    0.065   0.726    0.397    CHF2
          0.997    0.962    0.676     0.997   0.806    0.136   0.756    0.818    NSR
Weighted Avg.                     0.673    0.644    0.611     0.673   0.552    0.114   0.742    0.664

==== Confusion Matrix ====
      a   b   c  <- classified as
4   4 162 |
4   6 293 |
1   2 949 |  b = CHF1
              a = CHF2
              c = NSR
```

Gambar 5.4 Contoh Hasil Klasifikasi ANN

## **BAB VI**

### **HASIL DAN PEMBAHASAN**

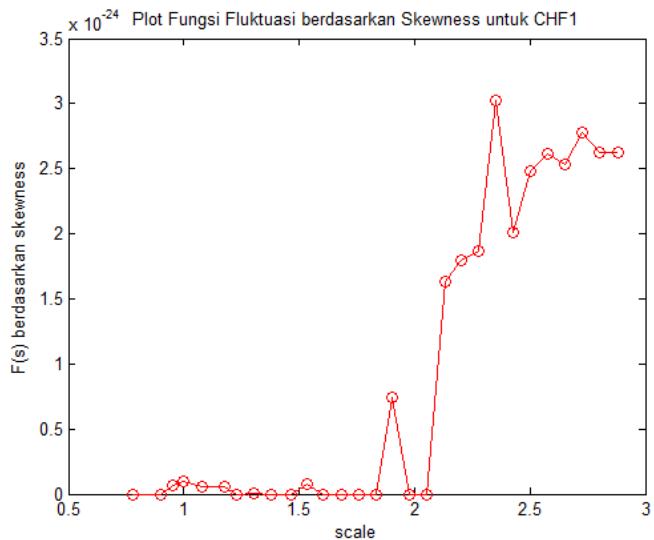
Pada bab ini berisi mengenai hasil dan pembahasan setelah melakukan implementasi. Hasil yang akan dijelaskan adalah hasil dari signifikansi Higher-Order Moments Detrended Fluctuation Analysis dan hasil klasifikasi ANN.

#### **6.1. Hasil Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis**

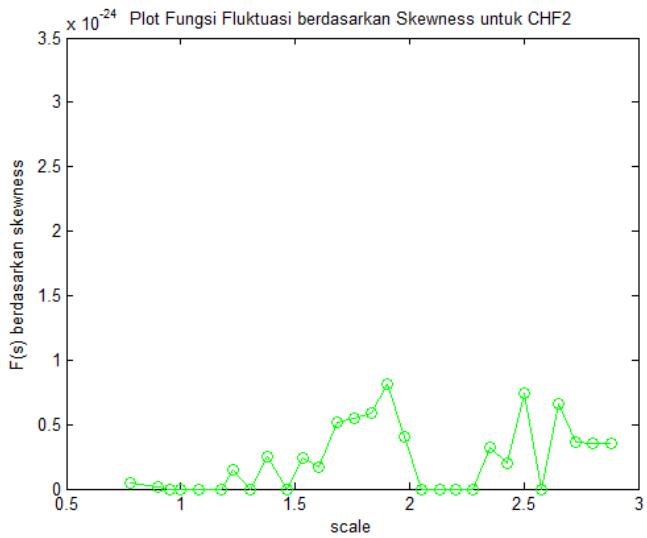
Metode ekstraksi fitur Higher-Order Moments Detrended Fluctuation Analysis menghasilkan empat nilai yaitu fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* dan *local scaling exponent* berdasarkan *skewness* dan *kurtosis*.

Gambar 6.1 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai *Skewness* untuk CHF1, Gambar 6.2 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai Skewness untuk CHF2, dan Gambar 6.3 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai Skewness untuk NSR merupakan contoh hasil plot fungsi fluktuasi berdasarkan nilai *skewness* untuk data CHF1, CHF2, dan NSR secara berturut-turut. Nilai Y-axis merupakan nilai fungsi fluktuasi berdasarkan nilai *skewness*, sedangkan nilai X-axis merupakan nilai segment yang telah dilakukan perhitungan log.

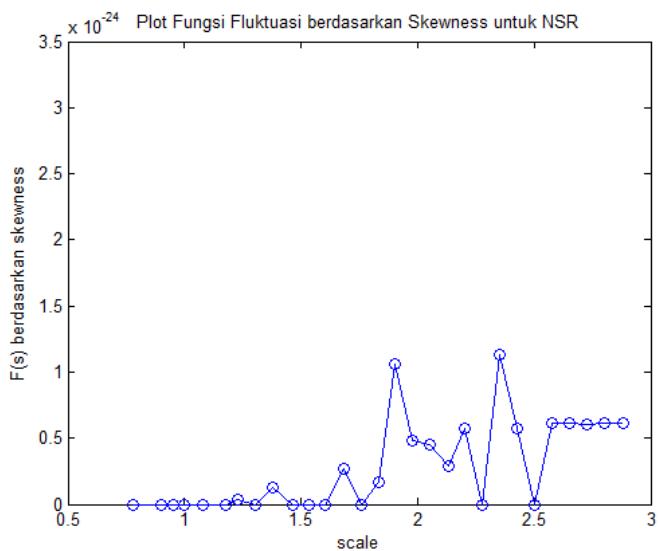
Hasil plot keseluruhan nilai fungsi fluktuasi berdasarkan skewness dapat dilihat pada Gambar 6.4, Gambar 6.5, dan Gambar 6.6. Gambar 6.4 merupakan hasil plot fungsi fluktuasi berdasarkan nilai skewness untuk data CHF1, Gambar 6.5 merupakan hasil plot fungsi fluktuasi berdasarkan nilai skewness untuk data CHF2, dan Gambar 6.6 merupakan hasil plot fungsi fluktuasi berdasarkan skewness untuk data NSR.



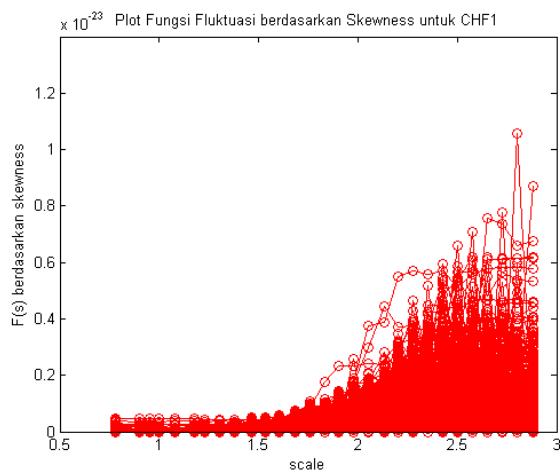
Gambar 6.1 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai Skewness untuk CHF1



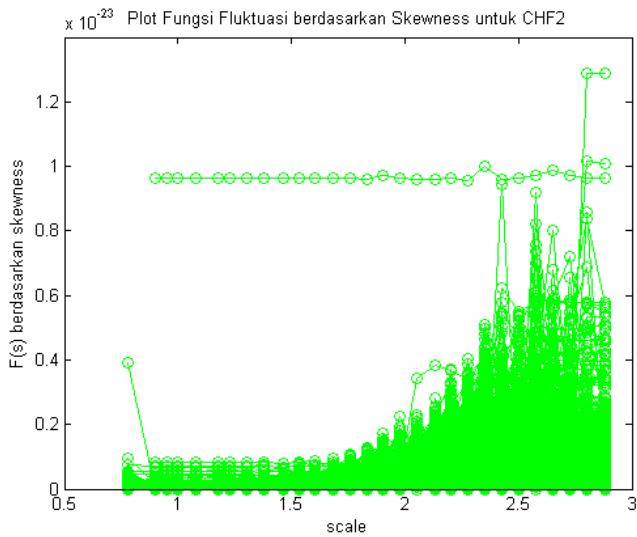
Gambar 6.2 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai Skewness untuk CHF2



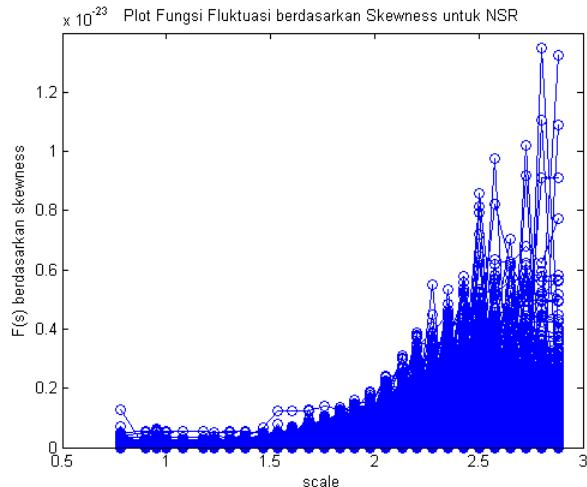
**Gambar 6.3 Contoh Plot Fungsi Fluktuasi berdasarkan Nilai Skewness untuk NSR**



**Gambar 6.4 Plot Fungsi Fluktuasi berdasarkan *Skewness* untuk Data CHF1**

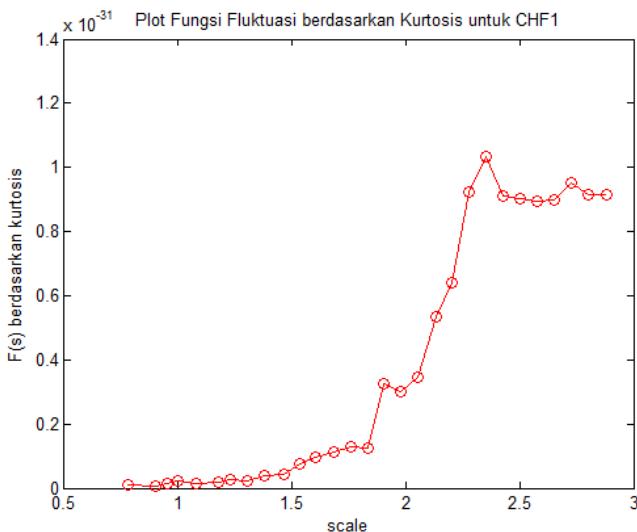


**Gambar 6.5 Plot Fungsi Fluktuasi berdasarkan *Skewness* untuk Data CHF2**



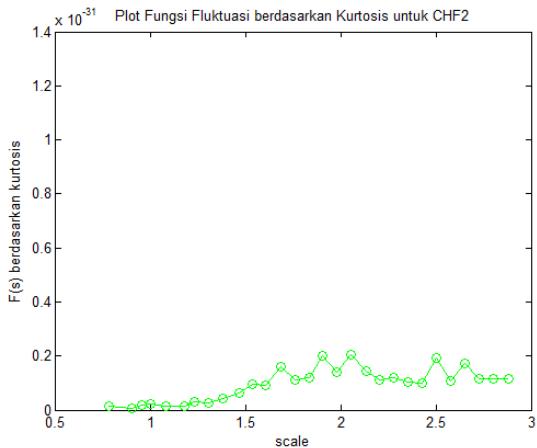
**Gambar 6.6 Plot Fungsi Fluktuasi berdasarkan *Skewness* untuk Data NSR**

Gambar 6.7 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk CHF1, Gambar 6.8 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk CHF2, dan Gambar 6.9 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk NSR merupakan contoh hasil plot fungsi fluktuasi berdasarkan nilai *kurtosis* untuk data CHF1, CHF2, dan NSR secara berturut-turut. Nilai Y-axis merupakan nilai fungsi fluktuasi berdasarkan nilai *kurtosis*, sedangkan nilai X-axis merupakan nilai segment yang telah dilakukan perhitungan log.

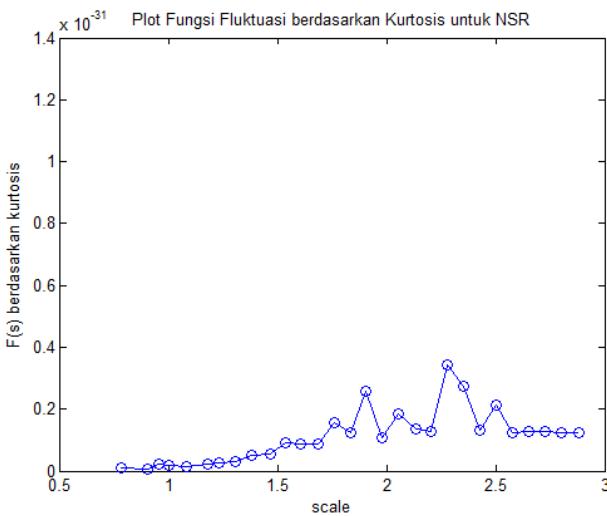


**Gambar 6.7 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk CHF1**

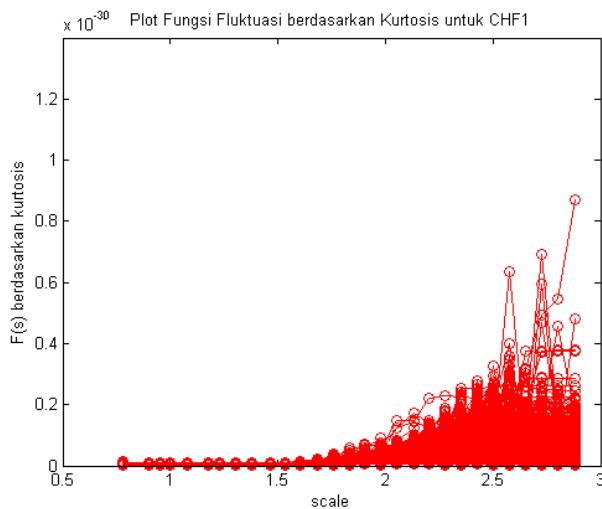
Hasil plot keseluruhan nilai fungsi fluktuasi berdasarkan kurtosis dapat dilihat pada Gambar 6.10, Gambar 6.11, dan Gambar 6.12. Gambar 6.10 merupakan hasil plot fungsi fluktuasi berdasarkan nilai kurtosis untuk data CHF1, Gambar 6.11 merupakan hasil plot fungsi fluktuasi berdasarkan nilai kurtosis untuk data CHF2, dan Gambar 6.12 merupakan hasil plot fungsi fluktuasi berdasarkan kurtosis untuk data NSR.



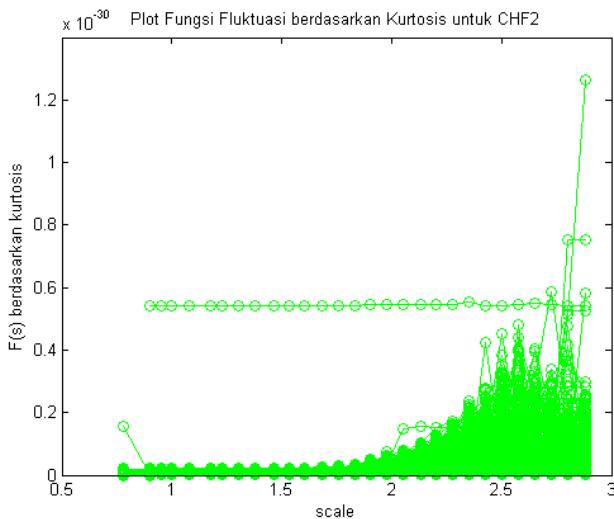
**Gambar 6.8 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk CHF2**



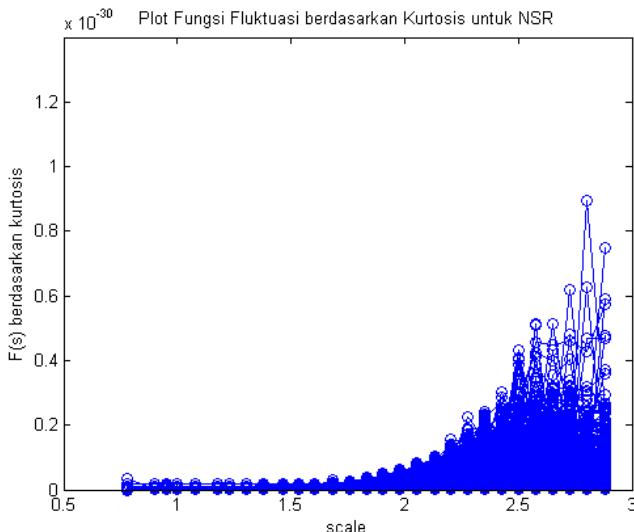
**Gambar 6.9 Contoh Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk NSR**



Gambar 6.10 Plot Fungsi Fluktuasi berdasarkan **Kurtosis** untuk Data CHF1



Gambar 6.11 Plot Fungsi Fluktuasi berdasarkan **Kurtosis** untuk Data CHF2

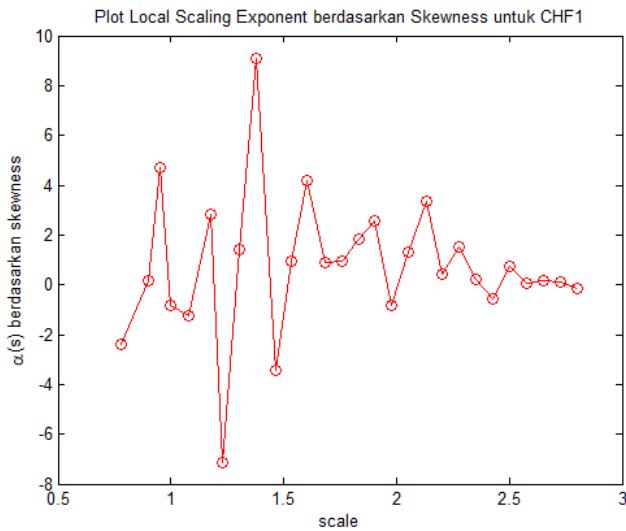


**Gambar 6.12 Plot Fungsi Fluktuasi berdasarkan Kurtosis untuk Data NSR**

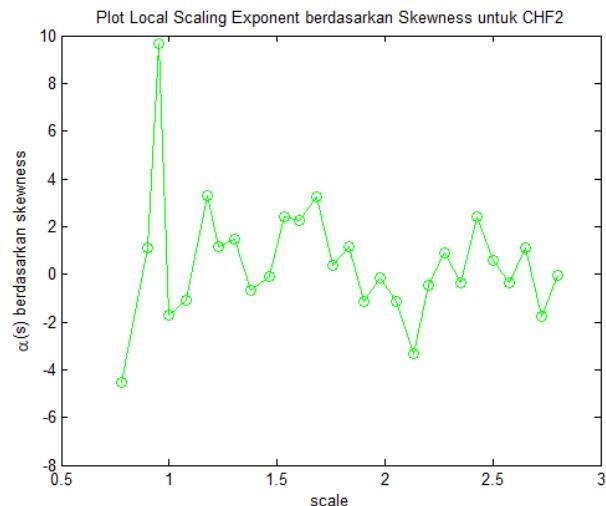
Gambar 6.13 Contoh Plot *Local Scaling Exponent* berdasarkan *Skewness* untuk CHF1, Gambar 6.14 Contoh Plot *Local Scaling Exponent* berdasarkan *Skewness* untuk CHF2, dan Gambar 6.15 Contoh Plot *Local scaling exponent* berdasarkan *Skewness* untuk NSR merupakan contoh hasil plot *local scaling exponent* berdasarkan nilai *skewness* untuk data CHF1, CHF2 dan NSR secara berturut-turut. Nilai Y-axis merupakan nilai *local scaling exponent* berdasarkan nilai *skewness*, sedangkan nilai X-axis merupakan nilai segment yang telah dilakukan perhitungan log.

Hasil plot keseluruhan nilai *local scaling exponent* berdasarkan *skewness* dapat dilihat pada Gambar 6.16, Gambar 6.17, dan Gambar 6.18. Gambar 6.16 merupakan hasil plot *local scaling exponent* berdasarkan nilai *skewness* untuk data CHF1, Gambar 6.17 merupakan hasil plot *local scaling exponent* berdasarkan nilai *skewness* untuk data CHF2, dan

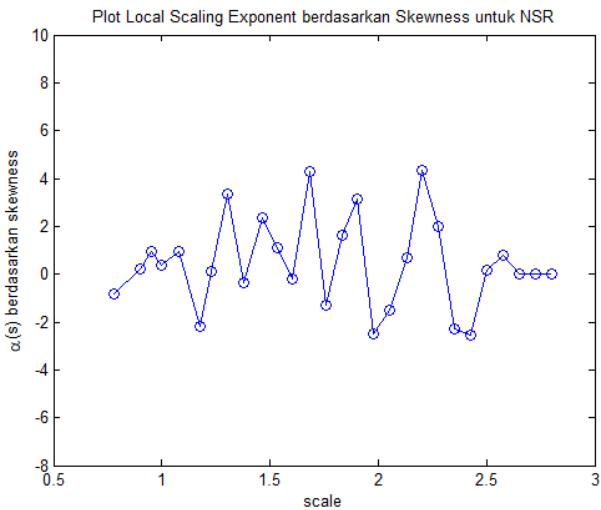
Gambar 6.18 merupakan hasil plot local scaling exponent berdasarkan skewness untuk data NSR.



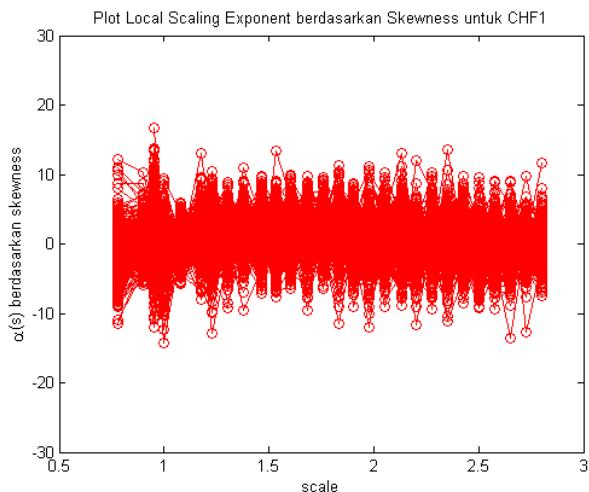
Gambar 6.13 Contoh Plot Local Scaling Exponent berdasarkan Skewness untuk CHF1



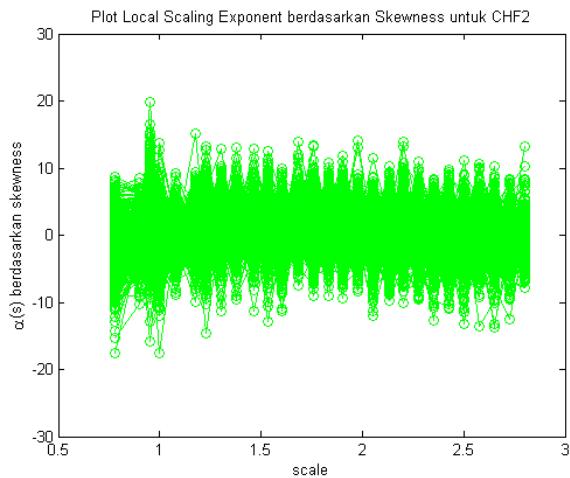
Gambar 6.14 Contoh Plot Local Scaling Exponent berdasarkan Skewness untuk CHF2



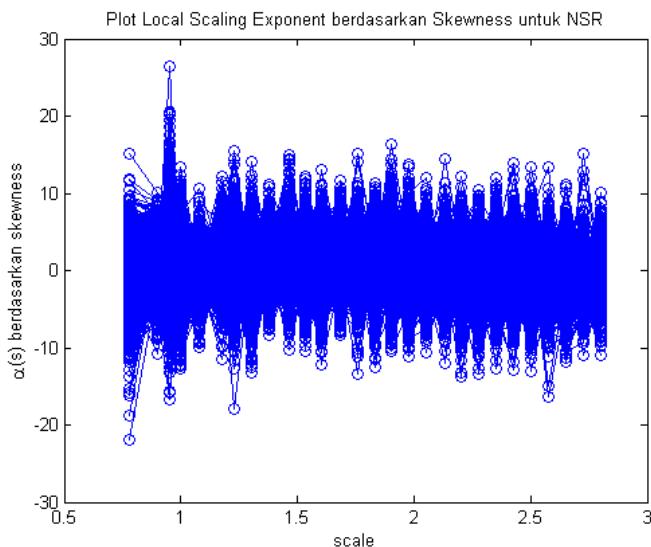
**Gambar 6.15 Contoh Plot Local scaling exponent berdasarkan Skewness untuk NSR**



**Gambar 6.16 Hasil Plot Local scaling exponent berdasarkan Skewness untuk Data CHF1**



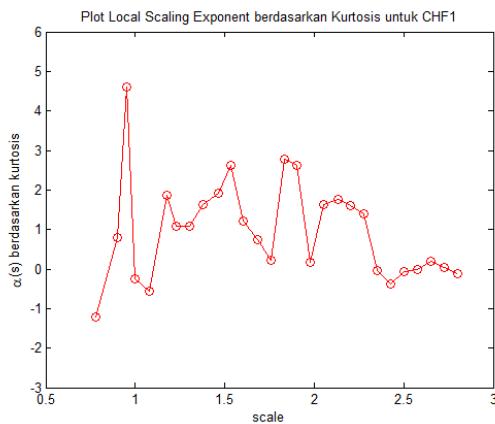
Gambar 6.17 Hasil Plot *Local scaling exponent* berdasarkan *Skewness* untuk Data CHF2



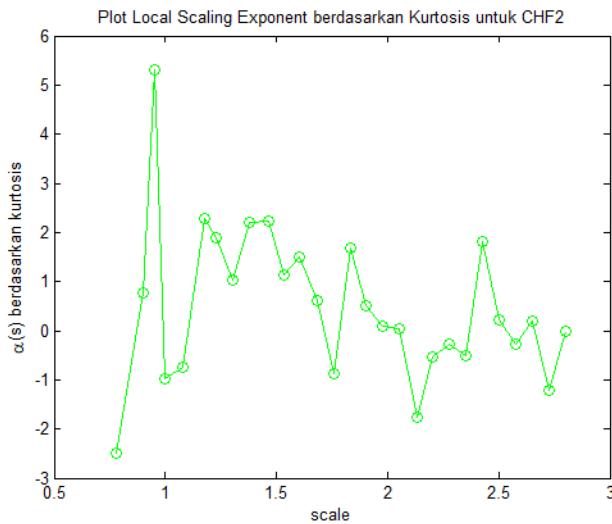
Gambar 6.18 Hasil Plot *Local scaling exponent* Berdasarkan *Skewness* Untuk Data NSR

Gambar 6.19 Contoh Plot *Local scaling exponent* berdasarkan *Kurtosis* untuk CHF1, Gambar 6.20 Contoh Plot *Local scaling exponent* berdasarkan *Kurtosis* untuk CHF2, dan Gambar 6.21 Contoh Plot *Local scaling exponent* berdasarkan *Kurtosis* untuk NSR merupakan hasil plot *local scaling exponent* berdasarkan nilai *kurtosis* untuk data CHF1, CHF2 dan NSR secara berturut-turut. Nilai Y-axis merupakan merupakan nilai *local scaling exponent* berdasarkan nilai *kurtosis*, sedangkan nilai X-axis merupakan nilai segment yang telah dilakukan perhitungan log.

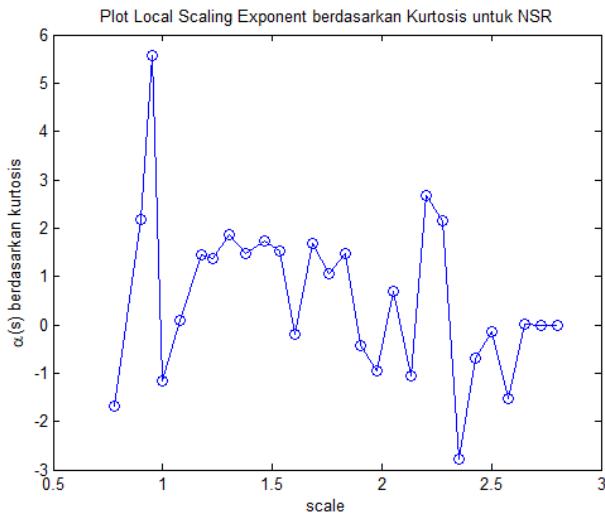
Hasil plot keseluruhan nilai local scaling exponent berdasarkan kurtosis dapat dilihat pada Gambar 6.22, Gambar 6.23, dan Gambar 6.24. Gambar 6.22 merupakan hasil plot local scaling exponent berdasarkan nilai kurtosis untuk data CHF1, Gambar 6.23 merupakan hasil plot local scaling exponent berdasarkan nilai kurtosis untuk data CHF2, dan Gambar 6.24 merupakan hasil plot local scaling exponent berdasarkan kurtosis untuk data NSR.



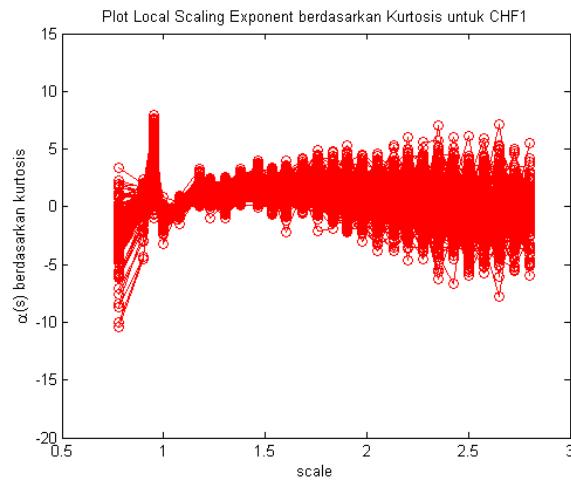
**Gambar 6.19 Contoh Plot *Local scaling exponent* berdasarkan *Kurtosis* untuk CHF1**



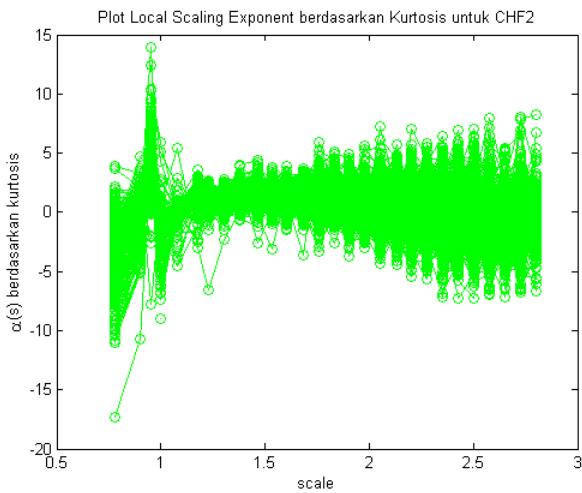
Gambar 6.20 Contoh Plot Local scaling exponent berdasarkan Kurtosis untuk CHF2



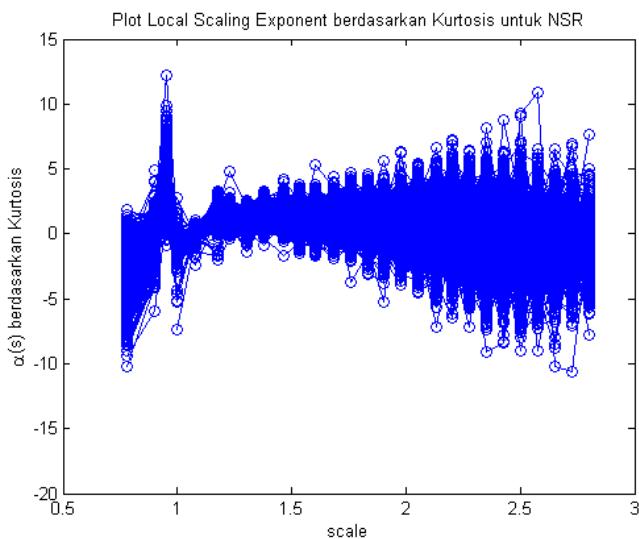
Gambar 6.21 Contoh Plot Local scaling exponent berdasarkan Kurtosis untuk NSR



Gambar 6.22 Hasil Plot *Local scaling exponent* berdasarkan *Kurtosis* untuk Data CHF1



Gambar 6.23 Hasil Plot *Local scaling exponent* berdasarkan *Kurtosis* untuk Data CHF2



**Gambar 6.24 Hasil Plot *Local scaling exponent* berdasarkan *Kurtosis* untuk Data NSR**

## 6.2. Hasil Signifikansi Higher-Order Moments Detrended Fluctuation Analysis

Sebelum melakukan uji signifikansi, data parameter harus dibersihkan terlebih dahulu dengan menghilangkan nilai NaN. Setelah membersihkan data parameter, didapatkan bahwa hanya parameter fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* saja yang dapat digunakan, karena parameter *local scaling exponent* memiliki nilai NaN pada titik pertama sehingga tidak dapat digunakan.

Rata-rata hasil uji signifikansi dari hasil ekstraksi fitur yaitu fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* pada masing-masing percobaan model Higher-Order Moments Detrended Fluctuation Analysis dijabarkan pada Tabel 6.1

**Tabel 6.1 Hasil Signifikansi output Higher-Order Moments Detrended Fluctuation Analysis**

Panjang Data	Kode	Tipe	Signifikansi
15 menit	Sig1	Rata-rata signifikansi chf1 dan chf2 untuk Fungsi fluktuasi berdasarkan <i>skewness</i>	N.S.
	Sig2	Rata-rata signifikansi chf1 dan nsr untuk Fungsi fluktuasi berdasarkan <i>skewness</i>	N.S.
	Sig3	Rata-rata signifikansi chf2 dan nsr untuk Fungsi fluktuasi berdasarkan <i>skewness</i>	N.S.
	Sig4	Rata-rata signifikansi chf1 dan chf2 untuk Fungsi fluktuasi berdasarkan <i>kurtosis</i>	$P \leq 0.05$
	Sig5	Rata-rata signifikansi chf1 dan nsr untuk Fungsi fluktuasi berdasarkan <i>kurtosis</i>	$P \leq 0.05$
	Sig6	Rata-rata signifikansi chf2 dan nsr untuk Fungsi fluktuasi berdasarkan <i>kurtosis</i>	$P \leq 0.05$
20 menit	Sig1	Rata-rata signifikansi chf1 dan chf2 untuk Fungsi fluktuasi berdasarkan <i>skewness</i>	N.S.
	Sig2	Rata-rata signifikansi chf1 dan nsr untuk Fungsi fluktuasi berdasarkan <i>skewness</i>	N.S.
	Sig3	Rata-rata signifikansi	N.S.

Panjang Data	Kode	Tipe	Signifikansi
		chf2 dan nsr untuk Fungsi fluktuasi berdasarkan <i>skewness</i>	
	Sig4	Rata-rata signifikansi chf1 dan chf2 untuk Fungsi fluktuasi berdasarkan <i>kurtosis</i>	$P \leq 0.05$
	Sig5	Rata-rata signifikansi chf1 dan nsr untuk Fungsi fluktuasi berdasarkan <i>kurtosis</i>	$P \leq 0.05$
	Sig6	Rata-rata signifikansi chf2 dan nsr untuk Fungsi fluktuasi berdasarkan <i>kurtosis</i>	$P \leq 0.05$

Dari Tabel 6.1 Hasil Signifikansi output Higher-Order Moments Detrended Fluctuation Analysis dapat dilihat bahwa untuk semua panjang data, nilai parameter fungsi fluktuasi berdasarkan *kurtosis* untuk chf1 dan chf2 memiliki nilai *p-value* kurang dari 0.05, yang berarti bahwa parameter tersebut memiliki perbedaan yang signifikan. Sedangkan untuk parameter fungsi fluktuasi berdasarkan *skewness* untuk chf1 dan chf2 memiliki nilai *p-value* lebih dari 0.05, yang berarti bahwa parameter tersebut tidak memiliki perbedaan yang signifikan.

Pada percobaan pertama Higher-Order Moments Detrended Fluctuation Analysis, signifikansi pada output parameter fungsi fluktuasi berdasarkan *skewness* untuk chf1 dan nsr (sig2) menghasilkan nilai *p-value* yang melebihi 0.05 (N.S.). Sedangkan fungsi fluktuasi berdasarkan *kurtosis* untuk chf1 dan nsr (sig5) menghasilkan nilai *p-value* kurang dari 0.05. Signifikansi pada output parameter fungsi fluktuasi berdasarkan *skewness* untuk chf2 dan nsr (sig3) menghasilkan

nilai *p-value* melebihi 0.05. Sedangkan untuk parameter fungsi fluktuasi berdasarkan *kurtosis* untuk chf2 dan nsr (sig6) menghasilkan nilai *p-value* kurang dari 0.05. Hal ini berarti bahwa hanya parameter fungsi fluktuasi berdasarkan *kurtosis* saja yang lolos uji signifikansi untuk panjang data yaitu 15 menit.

Pada percobaan kedua Higher-Order Moments Detrended Fluctuation Analysis, signifikansi pada output parameter fungsi fluktuasi berdasarkan *skewness* untuk chf1 dan nsr (sig2) menghasilkan nilai *p-value* yang melebihi 0.05. Sedangkan untuk parameter fungsi fluktuasi berdasarkan *kurtosis* untuk chf1 dan nsr (sig5) menghasilkan nilai *p-value* kurang dari 0.05. Signifikansi pada output parameter fungsi fluktuasi berdasarkan *skewness* untuk chf2 dan nsr (sig3) menghasilkan nilai *p-value* yang melebihi 0.05. Sedangkan parameter fungsi fluktuasi berdasarkan *kurtosis* (sig6) memiliki nilai *p-value* kurang dari 0.05. Hal ini berarti bahwa hanya parameter fungsi fluktuasi berdasarkan *kurtosis* saja yang lolos uji signifikansi untuk panjang data yaitu 15 menit.

Dari dua percobaan tersebut, didapatkan hasil bahwa parameter yang lolos uji signifikansi adalah parameter fungsi fluktuasi berdasarkan *kurtosis* (sig4, sig5, dan sig5). Hal ini berarti bahwa hanya parameter tersebut yang dapat digunakan sebagai input dari klasifikasi ANN.

### 6.3. Hasil Klasifikasi ANN

Data output *Higher-Order Moments Detrended Fluctuation Analysis* akan diuji klasifikasi antara data training dengan data testing untuk mendapatkan model terbaik. Uji klasifikasi dilakukan sebanyak 225 kali dengan mengganti model ANN sesuai dengan Tabel 4.1 **Uji Model ANN**. Tabel 6.2 Sebagian Hasil Uji Klasifikasi untuk Panjang Data 15 menit merupakan sebagian dari hasil uji klasifikasi untuk panjang data 15 menit dan Tabel 6.3 Sebagian Hasil Uji Klasifikasi untuk Panjang Data 20 menit merupakan sebagian dari hasil uji klasifikasi untuk panjang data 20 menit dengan mengubah jumlah node

pada *hidden layer* dari 2-4 node, 16 node, dan 20 node, mengubah nilai *learning rate* dari 0.1 sampai 0.9 dan mengubah nilai *momentum* dari 0.5 sampai 0.9. Dari hasil tersebut, akan diambil model yang memiliki nilai akurasi tertinggi sebagai model terbaik. Hasil keseluruhan dari uji klasifikasi dapat dilihat pada LAMPIRAN A untuk panjang data 15 menit dan LAMPIRAN B untuk panjang data 20 menit.

**Tabel 6.2 Sebagian Hasil Uji Klasifikasi untuk Panjang Data 15 menit**

Jumlah Hidden Layer	Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
1	2	0,1	0.5	69.05%	0.00	0.69	0.82
			0.6	69.40%	0.00	0.69	0.81
			0.7	69.75%	0.00	0.70	0.80
			0.8	68.84%	0.00	0.69	0.79
			0.9	71.58%	0.00	0.72	0.80
		0,2	0.5	69.75%	0.00	0.70	0.80
			0.6	70.18%	0.00	0.70	0.80
			0.7	71.16%	0.00	0.71	0.78
			0.8	71.44%	0.00	0.71	0.79
			0.9	69.33%	0.00	0.69	0.74

**Tabel 6.3 Sebagian Hasil Uji Klasifikasi untuk Panjang Data 20 menit**

Jumlah Hidden Layer	Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
1	2	0,1	0.5	69.05%	0.64	0.69	0.80
			0.6	68.76%	0.64	0.69	0.80

Jumlah Hidden Layer	Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
			0.7	69.24%	0.69	0.69	0.79
			0.8	67.90%	0.74	0.68	0.78
			0.9	70.67%	0.00	0.71	0.75
		0.2	0.5	69.24%	0.74	0.69	0.78
			0.6	68.76%	0.74	0.69	0.78
			0.7	67.33%	0.00	0.67	0.79
			0.8	70.19%	0.69	0.70	0.76
			0.9	70.10%	0.00	0.70	0.78

Setelah mendapatkan model terbaik, barulah dicari nilai akurasi dengan melakukan uji klasifikasi terhadap data validasi. Hasil klasifikasi *Higher-Order Moments Detrended Fluctuation Analysis* antara data training dan data testing dan model terbaik dari parameter ANN yang diuji beserta hasil akurasinya terdapat pada Tabel 6.4

**Tabel 6.4 Hasil Klasifikasi output Higher-Order Moments Detrended Fluctuation Analysis**

Panjang Data	Jumlah Hidden Layer	Node pada Hidden Layer	Momen-tum	Lear-nning Rate	Akurasi
15 menit	1	4	0.7	0.1	72.07%
20 menit	1	16	0.9	0.2	72.67%

Tabel 6.4 Hasil Klasifikasi output Higher-Order Moments Detrended Fluctuation Analysis menunjukkan bahwa hasil klasifikasi dari ekstraksi fitur *Higher-Order Moments Detrended Fluctuation Analysis* dengan panjang data 25 menit

menghasilkan akurasi terbaik sebesar 72.07 % dengan parameter node pada *hidden layer*, *momentum*, dan *learning rate* secara berurutan yaitu 4, 0.7, dan 0.1.

Hasil klasifikasi dari ekstraksi fitur *Higher-Order Moments Detrended Fluctuation Analysis* dengan panjang data 20 menit menghasilkan akurasi terbaik sebesar 72.67% dengan parameter node pada *hidden layer*, *momentum*, dan *learning rate* secara berurutan yaitu 16, 0.9, dan 0.2.

Hasil akurasi dengan parameter *hidden layer*, *momentum*, *learning rate* secara berurutan yaitu 16, 0.9, dan 0.2 yang didapatkan dengan menggunakan *k-fold cross validation* ini tidak begitu baik karena hasil klasifikasi yang didapatkan untuk label chf1 dan chf2 tidak dapat diklasifikasikan dengan baik, hanya beberapa saja yang benar dalam mengklasifikasikan chf1 dan chf2 sesuai label. Contoh hasil prediksi dan status pada label dapat dilihat pada Tabel 6.5 **Contoh Hasil Klasifikasi ANN Prediksi dengan Status**. Dari Tabel 6.5 **Contoh Hasil Klasifikasi ANN Prediksi dengan Status**, dapat dilihat bahwa terdapat perbedaan antara hasil prediksi dan status asli yang dimiliki oleh suatu data.

**Tabel 6.5 Contoh Hasil Klasifikasi ANN Prediksi dengan Status**

No	F(s) Kurtosis titik pertama	F(s) Kurtosis titik kedua	Prediksi Status	Status
1	$1.09496 \times 10^{-33}$	$1,70 \times 10^{-33}$	CHF1	CHF1
2	$1.14055 \times 10^{-33}$	$1,57 \times 10^{-33}$	NSR	CHF1
3	$1.5336 \times 10^{-33}$	$1,40 \times 10^{-33}$	NSR	CHF1
4	$1.3086 \times 10^{-33}$	$1,15 \times 10^{-33}$	CHF1	CHF1
5	$1.21307 \times 10^{-33}$	$1,38 \times 10^{-33}$	NSR	CHF1
6	$1.37176 \times 10^{-33}$	$1,56 \times 10^{-33}$	NSR	CHF1
7	$1.22777 \times 10^{-33}$	$1,87 \times 10^{-33}$	NSR	CHF1
8	$1.13626 \times 10^{-33}$	$1,65 \times 10^{-33}$	CHF1	CHF1
9	$1.20875 \times 10^{-33}$	$1,86 \times 10^{-33}$	NSR	CHF1
10	$1.18937 \times 10^{-33}$	$1,32 \times 10^{-33}$	NSR	CHF1

No	F(s) <i>Kurtosis</i> titik pertama	F(s) <i>Kurtosis</i> titik kedua	Prediksi Status	Status
11	$1.36914 \times 10^{-33}$	$1,76 \times 10^{-33}$	NSR	CHF1
12	$1.07377 \times 10^{-33}$	$1,36 \times 10^{-33}$	NSR	CHF1
13	$9.68674 \times 10^{-34}$	$1,44 \times 10^{-33}$	NSR	CHF1
14	$9.16037 \times 10^{-34}$	$1,46 \times 10^{-33}$	NSR	CHF1
15	$1.52315 \times 10^{-33}$	$1,38 \times 10^{-33}$	CHF1	CHF1
16	$1.20426 \times 10^{-33}$	$1,61 \times 10^{-33}$	CHF1	CHF1
17	$1.43463 \times 10^{-33}$	$1,63 \times 10^{-33}$	CHF1	CHF1
18	$1.04348 \times 10^{-33}$	$1,65 \times 10^{-33}$	CHF1	CHF1
19	$1.18908 \times 10^{-33}$	$1,73 \times 10^{-33}$	NSR	CHF1
20	$1.48538 \times 10^{-33}$	$1,61 \times 10^{-33}$	NSR	CHF1
21	$1.42699 \times 10^{-33}$	$1,64 \times 10^{-33}$	CHF2	CHF1
22	$1.16194 \times 10^{-33}$	$1,08 \times 10^{-32}$	NSR	CHF1
23	$1.00232 \times 10^{-33}$	$1,57 \times 10^{-33}$	CHF1	CHF1
24	$8.18317 \times 10^{-34}$	$1,77 \times 10^{-33}$	CHF2	CHF1
25	$1.13964 \times 10^{-33}$	$1,75 \times 10^{-33}$	CHF1	CHF1
26	$1.18107 \times 10^{-33}$	$1,79 \times 10^{-33}$	CHF1	CHF1
27	$1.16911 \times 10^{-33}$	$1,61 \times 10^{-33}$	CHF1	CHF1
28	$1.2575 \times 10^{-33}$	$1,81 \times 10^{-33}$	CHF2	CHF1
29	$1.45665 \times 10^{-33}$	$1,46 \times 10^{-33}$	CHF2	CHF1
30	$1.22563 \times 10^{-33}$	$1,41 \times 10^{-33}$	CHF1	CHF1
31	$1.2552 \times 10^{-33}$	$1,73 \times 10^{-33}$	CHF1	CHF1
32	$1.01199 \times 10^{-33}$	$1,61 \times 10^{-33}$	CHF1	CHF1
33	$1.22785 \times 10^{-33}$	$1,62 \times 10^{-33}$	CHF2	CHF1
34	$1.26062 \times 10^{-33}$	$2,08 \times 10^{-33}$	CHF2	CHF1
35	$1.12703 \times 10^{-33}$	$1,85 \times 10^{-33}$	CHF1	CHF1
...				
6654	$1.3988 \times 10^{-33}$	$1.3988 \times 10^{-33}$	NSR	NSR

#### 6.4. Hasil Uji Validasi

Hasil uji klasifikasi yang telah dilakukan pada tahap sebelumnya akan dihitung uji validasinya. Validasi dilakukan terhadap model ANN dengan parameter terbaik. Validasi dilakukan menggunakan *Confusion Matrix* dan ROC dari masing-masing uji klasifikasi. Tabel 6.10 Hasil Uji Validasi menjelaskan hasil *confusion matrix* terhadap model ANN terbaik untuk panjang data 15 menit.

**Tabel 6.6 Confusion Matrix untuk Hasil Klasifikasi pada Data 15 Menit**

Kelas Sesungguhnya	Diklasifikasikan sebagai		
	CHF1	CHF2	NSR
CHF1	35	14	121
CHF2	18	52	232
NSR	2	10	940

Dari Tabel 6.10 Hasil Uji Validasi didapatkan hasil *precision* dan *recall* untuk masing-masing kelas adalah seperti pada Tabel 6.7 Nilai *Precision* dan *Recall* untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 15 Menit.

**Tabel 6.7 Nilai Precision dan Recall untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 15 Menit**

Kelas	Precision	Recall
CHF1	0.64	0.21
CHF2	0.68	0.17
NSR	0.73	0.99

Dari Tabel 6.7 Nilai *Precision* dan *Recall* untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 15 Menit dapat diketahui bahwa untuk uji klasifikasi percobaan pertama yaitu uji klasifikasi terhadap data 15 menit masih terdapat data CHF1, CHF2, dan NSR yang tidak diklasifikasikan sesuai dengan kelas yang seharusnya. Hal ini dapat dilihat dari nilai *recall*-nya yang rendah. *Recall* mengukur berapa banyak instans dari kelas tertentu yang dapat diprediksi secara benar, sehingga nilai *recall* yang rendah berarti hanya sedikit data

yang berhasil diklasifikasikan ke dalam kelas tersebut. Kelas CHF1, CHF2, dan NSR memiliki nilai *recall* yang rendah yang berarti bahwa hanya sedikit data yang berhasil diklasifikasikan ke kelas tersebut. Hal ini dapat dilihat pada Tabel 6.6 *Confusion Matrix* untuk Hasil Klasifikasi pada Data 15 Menit yang menunjukkan bahwa pada kelas CHF1, hanya 35 data CHF1 saja yang berhasil diklasifikasikan sebagai CHF1, selebihnya diklasifikasikan pada dua kelas lain. *Precision* dapat mengukur ketepatan prediksi pengklasifikasi pada kelas tertentu, sehingga nilai *precision* yang tinggi berarti bahwa data yang diklasifikasikan tepat sesuai dengan kelas yang seharusnya. Dari hasil Tabel 6.7 Nilai *Precision* dan *Recall* untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 15 Menit, dapat diketahui bahwa masih banyak data yang diklasifikasikan ke dalam kelas yang salah. Dapat dilihat dari Tabel 6.6 *Confusion Matrix* untuk Hasil Klasifikasi pada Data 15 Menit dimana data yang diklasifikasikan sebagai CHF1 berjumlah 55 data, namun yang 35 diantaranya yang memiliki kelas CHF1.

Tabel 6.8 *Confusion Matrix* untuk Hasil Klasifikasi pada Data 20 Menit merupakan hasil dari uji validasri terhadap model ANN terbaik untuk panjang data 20 menit.

**Tabel 6.8 Confusion Matrix untuk Hasil Klasifikasi pada Data 20 Menit**

Kelas Sesungguhnya	Diklasifikasikan sebagai		
	CHF1	CHF2	NSR
CHF1	4	4	162
CHF2	4	6	293
NSR	1	2	949

Dari Tabel 6.8 *Confusion Matrix* untuk Hasil Klasifikasi pada Data 20 Menit didapatkan hasil *precision* dan *recall* untuk masing-masing kelas adalah seperti pada Tabel 6.9 Nilai *Precision* dan *Recall* untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 20 Menit.

**Tabel 6.9 Nilai *Precision* dan *Recall* untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 20 Menit**

Kelas	<i>Precision</i>	<i>Recall</i>
CHF1	0.44	0.02
CHF2	0.50	0.02
NSR	0.68	1.00

Dari Tabel 6.9 Nilai *Precision* dan *Recall* untuk Masing-Masing Kelas pada Hasil Klasifikasi Data 20 Menit dapat diketahui bahwa untuk uji klasifikasi percobaan kedua yaitu uji klasifikasi terhadap data 20 menit masih terdapat data CHF1 dan CHF2 yang tidak diklasifikasikan sesuai dengan kelas yang seharusnya.

Kelas CHF1 dan CHF2 memiliki nilai *recall* yang rendah yang berarti bahwa hanya sedikit data yang berhasil diklasifikasikan ke kelas tersebut. Hal ini dapat dilihat dari Tabel 6.8 *Confusion Matrix* untuk Hasil Klasifikasi pada Data 20 Menit dimana hanya 4 data CHF1 yang berhasil diklasifikasikan sebagai CHF1 dan 6 data CH2 yang berhasil diklasifikasikan sebagai CHF2. Sedangkan pada kelas NSR, hampir seluruh data dengan kelas NSR berhasil diklasifikasikan ke dalam kelas NSR. Hal ini dapat dilihat dari Tabel 6.8 *Confusion Matrix* untuk Hasil Klasifikasi pada Data 20 Menit dimana terdapat 949 data NSR yang berhasil diklasifikasikan sebagai NSR. *Precision* dapat mengukur ketepatan prediksi pengklasifikasi pada kelas tertentu, sehingga nilai *precision* yang tinggi berarti bahwa data yang diklasifikasikan tepat sesuai dengan kelas yang seharusnya. Dari hasil tersebut, dapat diketahui bahwa masih banyak data yang diklasifikasikan ke dalam kelas yang salah. Dapat dilihat dari Tabel 6.8 *Confusion Matrix* untuk Hasil Klasifikasi pada Data 20 Menit dimana data yang diklasifikasikan sebagai CHF1 berjumlah 9, namun hanya 4 diantaranya yang memiliki kelas CHF1.

**Tabel 6.10 Hasil Uji Validasi**

Panjang Data	<i>Precision</i>	<i>Recall</i>	<i>Accuracy</i>	ROC
15 menit	0.664	0.712	71.23%	0.797
20 menit	0.675	0.714	71.43%	0.774

Tabel 6.10 Hasil Uji Validasi menunjukkan bahwa pada klasifikasi pertama dengan input hasil percobaan *Higher-Order Moments Detrended Fluctuation Analysis* dengan panjang data 15 menit menghasilkan nilai *precision* sebesar 0.664, nilai *recall* sebesar 0.712, akurasi sebesar 71.23%, dan nilai ROC yang dihasilkan adalah 0.794.

Hasil klasifikasi kedua dengan input hasil percobaan *Higher-Order Moments Detrended Fluctuation Analysis* dengan panjang data 20 menit menghasilkan nilai *precision* sebesar 0.675, nilai *recall* sebesar 0.714, nilai akurasi sebesar 71.43% dan nilai ROC sebesar 0.774.

Dari hasil uji validitas tersebut, dapat dikatakan bahwa klasifikasi dengan input *Higher-Order Moments Detrended Fluctuation Analysis* dengan parameter jumlah node pada *hidden layer*, *momentum*, *learning rate* secara berurutan yaitu 16, 0.9, dan 0.2 merupakan klasifikasi terbaik karena memiliki nilai *Precision*, *Recall* dan Akurasi yaitu 0.675, 0.714, dan 71.43% secara berurutan. Nilai ROC yang dihasilkan yaitu 0.797 dapat dikategorikan sebagai klasifikasi yang cukup baik.

Dari hasil klasifikasi yang didapatkan, dapat dikatakan bahwa hasil ekstraksi fitur *Higher-Order Moments Detrended Fluctuation Analysis* cukup baik untuk digunakan dalam input ANN. Dengan menggunakan metode *Higher-Order Moments Detrended Fluctuation Analysis*, sinyal HRV akan dihitung nilai *skewness* dan *kurtosis*-nya sehingga dapat mengetahui ukuran asimetris dari probabilitas distribusi rata-rata dan menghitung perubahan dari *tailedness*. Oleh karena itu, metode tersebut memiliki hasil yang cukup baik ketika digunakan pada data sinyal biomédik karena dapat meneliti volatility dari data sinyal HRV. Selain itu, dapat diketahui

pula bahwa hasil akurasi yang didapatkan belum termasuk klasifikasi yang baik. Hal ini terjadi karena sinyal HRV merupakan suatu sinyal yang *non-linear* dan kompleks, sehingga sulit untuk memproses dan memprediksi sinyal HRV.

*(Halaman ini sengaja dikosongkan)*

## **BAB VII**

### **KESIMPULAN DAN SARAN**

Pada bab ini dibahas mengenai kesimpulan dari seluruh proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangan yang lebih baik.

#### **7.1. Kesimpulan**

Beberapa kesimpulan yang bisa diambil dari penelitian tugas akhir ini adalah:

1. Metode Higher-Order Moments Detrended Fluctuation Analysis dapat diterapkan untuk mengekstraksi fitur pada sinyal HRV pasien gagal jantung kongestif.
2. Hasil signifikansi dari output fungsi fluktuasi berdasarkan *skewness* pada chf1 dan nsr menghasilkan *p-value* yang tidak signifikan, sedangkan output fungsi fluktuasi berdasarkan *kurtosis* pada chf1 dan nsr menghasilkan nilai *p-value* yang lebih dari 0.05 sehingga output tersebut dinyatakan signifikan. Hasil signifikansi dari output fungsi fluktuasi berdasarkan *skewness* pada chf2 dan nsr menghasilkan nilai *p-value* yang tidak signifikan, sedangkan output fungsi fluktuasi berdasarkan *kurtosis* menghasilkan nilai *p-value* yang lebih dari 0.05, sehingga output tersebut dinyatakan signifikan.
3. Hasil klasifikasi ANN menghasilkan akurasi terbaik sebesar 72.67% pada saat dilakukan uji klasifikasi data training terhadap data testing. Hasil klasifikasi tersebut didapatkan dengan parameter ANN jumlah node pada *hidden layer*, *momentum*, dan *learning rate* secara berurutan yaitu 16, 0.9, dan 0.2. Hasil klasifikasi pada saat dilakukan validasi adalah 71.43%, dengan nilai ROC yaitu 0.774. Klasifikasi tersebut tergolong cukup baik, dengan hasil akhir

ROC-nya yang termasuk ke dalam *range* 0.7-0.8 yang berarti bahwa klasifikasi dinyatakan cukup baik.

## 7.2. Saran

Saran yang dapat dipertimbangkan untuk pengembangan tugas akhir ini yaitu:

1. Pada penelitian ini masih belum terdapat perhitungan ekstraksi fitur dan klasifikasi melalui pembuatan aplikasi, sehingga untuk penelitian selanjutnya dapat dilanjutkan dengan pembuatan aplikasi.
2. Dapat digunakan metode tambahan klasifikasi lain yaitu *Support Vector Machine*, *Naïve Bayes*, atau C4.5 dalam melakukan klasifikasi untuk mendapatkan hasil akurasi yang lebih baik.
3. Dapat digunakan ekstraksi fitur metode lain seperti *linear* dan *non linear analysis* sebagai input ANN dalam melakukan klasifikasi dan menghasilkan akurasi yang lebih baik.

## DAFTAR PUSTAKA

- [1] World Health Organization, “Prevention of Cardiovascular Disease: Guidelines for assessment and management of cardiovascular risk.” 2007.
- [2] D. Mozaffarian *et al.*, *AHA Statistical Update Heart Disease and Stroke Statistics — 2016 Update A Report From the American Heart Association WRITING GROUP MEMBERS*. 2016.
- [3] Kementrian Kesehatan RI, “Penyakit Jantung Penyebab Kematian Tertinggi, Kemenkes Ingatkan CERDIK,” 2017. [Online]. Available: <http://www.depkes.go.id/article/view/17073100005/penyakit-jantung-penyebab-kematian-tertinggi-kemenkes-ingatkan-cerdik-.html>. [Accessed: 10-Sep-2017].
- [4] Mayo Clinic, “Heart failure Tests and diagnosis,” 2017. [Online]. Available: <http://www.mayoclinic.org/diseases-conditions/heart-failure/basics/tests-diagnosis/con-20029801>. [Accessed: 29-Sep-2017].
- [5] T. L. Hartono, F. D. Setiaji, I. Setyawan, P. Studi, T. Elektro, and F. Teknik, “Alat Bantu Analisis Heart Rate Variability,” *Techné J. Ilm. Elektrotek.*, vol. 12, no. 2, pp. 141–158, 2013.
- [6] R. Metelka, “Heart rate variability - current diagnosis of the cardiac autonomic neuropathy. A review,” *Biomed Pap Med Fac Univ Palacky Olomouc Czech Repub*, vol. 158, no. 3, pp. 327–338, 2014.
- [7] R. A. Putri, J. Y. Mindara, and S. R. I. Suryaningsih, “Rancang Bangun Wireless Elektrokardiogram (EKG),” *J. Ilmu dan Inov. Fis.*, vol. 1, no. 1, pp. 58–64, 2017.
- [8] P. Gifani, H. R. Rabiee, M. H. Hashemi, P. Taslimi, and M. Ghanbari, “Optimal fractal-scaling analysis of human EEG dynamic for depth of anesthesia

- quantification,” *J. Franklin Inst.*, vol. 344, pp. 212–229, 2007.
- [9] A. Leite, A. Rocha, and M. Silva, “Long memory and volatility in HRV : An ARFIMA- GARCH approach,” *Comput. Cardiol.*, vol. 36, pp. 165–168, 2009.
  - [10] J. Lee, D. Kim, I. Kim, K. Park, and S. I. Kim, “Detrended fluctuation analysis of EEG in sleep apnea using MIT/BIH polysomnography data,” *Comput. Biol. Med.*, vol. 32, pp. 37–47, 2002.
  - [11] Y. Teng and P. Shang, “Detrended fluctuation analysis based on higher-order moments of financial time series,” *Physica A*, 2017.
  - [12] H. Li *et al.*, “An artificial neural network prediction model of congenital heart disease based on risk factors,” *Medicine (Baltimore)*. , vol. 6, no. June 2016, 2017.
  - [13] F. Lucena, A. K. Barros, and N. Ohnishi, “The Performance of Short-Term Heart Rate Variability in the Detection of Congestive Heart Failure,” *Biomed Res. Int.*, vol. 2016, no. 1675785, 2016.
  - [14] D. Y. Ananta, “Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Multifractal Detrended Fluctuationa Analysis (MFDFA) Pada Variabilitas Denyut Jantung,” Institut Teknologi Sepuluh Nopember, 2017.
  - [15] R. Galaska *et al.*, “Comparison of Wavelet Transform Modulus Maxima and Multifractal Detrended Fluctuation Analysis of Heart Rate in Patients with Systolic Dysfunction of Left Ventricle,” pp. 155–164, 2008.
  - [16] T. Zorick and M. A. Mandelkern, “Multifractal Detrended Fluctuation Analysis of Human EEG : Preliminary Investigation and Comparison with the Wavelet Transform Modulus Maxima Technique,” vol. 8, no. 7, pp. 1–7, 2013.
  - [17] S. Dutta, D. Ghosh, S. Chatterjee, and F. Hasselman,

- “Multifractal detrended fluctuation analysis of human gait diseases,” vol. 4, no. October, pp. 1–7, 2013.
- [18] American Heart Association, “What is Cardiovascular Disease?,” 2017. [Online]. Available: [http://www.heart.org/HEARTORG/Conditions/What-is-Cardiovascular-Disease\\_UCM\\_301852\\_Article.jsp#.WcwXksgjHIU](http://www.heart.org/HEARTORG/Conditions/What-is-Cardiovascular-Disease_UCM_301852_Article.jsp#.WcwXksgjHIU). [Accessed: 28-Sep-2017].
- [19] Bina Kefarmasian dan Alat Kesehatan, *Pharmaceutical Care Untuk Pasien Penyakit Jantung Koroner : Fokus Sindrom Koroner Akut*. 2006.
- [20] T. Bahr and A. Djohan, “Penyakit Jantung Koroner Dan Hipertensi.” pp. 1–7, 2004.
- [21] T. N. American, “Heart rate variability: Standards of measurement, physiological interpretation, and clinical use Task,” *Eur. Heart J.*, vol. 17, pp. 354–381, 1996.
- [22] B. Cahyono, “Penggunaan Software Matrix Laboratory (MATLAB) Dalam Pembelajaran Aljabar Linier,” *J. Phenom.*, vol. 1, no. 1, pp. 45–62, 2013.
- [23] M. Chen, S. Member, J. Han, S. Member, and P. S. Yu, “Data Mining: An Overview from a Database Perspective,” *IEEE Trans. Knowl. Data Eng.*, vol. 8, no. 6, pp. 866–883, 1996.
- [24] J. Han, J. Pei, and M. Kamber, *Data Mining: Concepts and Techniques Third Edition*. 2011.
- [25] K. B. Johnston and H. M. Oluseyi, “Generation of a supervised classification algorithm for time-series variable stars with an application to the LINEAR dataset,” *New Astron.*, vol. 52, pp. 35–47, 2017.
- [26] A. K. Das, S. Goswami, A. Chakrabarti, and B. Chakraborty, “A new hybrid feature selection approach using Feature Association Map for supervised and unsupervised classification Amit,” *Expert Syst. Appl.*, 2017.
- [27] U. Hamida, “Penggunaan Artificial Neural Network (ANN) Untuk Memodelkan Kebutuhan Energi Untuk Transportasi,” *J. Teknol. dan Manaj.*, vol. 12, no. 2, pp.

- 57–65, 2014.
- [28] A. Barus, “Analisis Accelerated Learning Pada Backpropagation Dalam Peramalan Indeks Harga Saham Gabungan,” *J. Ilm. Res. Sains*, vol. 1, no. 3, pp. 154–165, 2015.
  - [29] E. Chandrasekhar, S. S. Prabhudesai, G. K. Seemala, and N. Shenvi, “Author’s Accepted Manuscript,” *J. Atmos. Solar-Terrestrial Phys.*, 2016.
  - [30] A. G. Bluman, *Elementary Statistics: A Step by Step Approach*. 2008.
  - [31] P. Flach, *Machine Learning: The Art and Science of Algorithms that Make Sense of Data*. Cambridge University Press, 2012.
  - [32] Suwarno and A. Abdillah, “Penerapan Algoritma Bayesian Regularization Backpropagation Untuk Memprediksi Penyakit Diabetes,” *J. MIPA*, vol. 39, no. 45, pp. 150–158, 2016.
  - [33] S. Karsoliya, “Approximating Number of Hidden layer nodes in Multiple Hidden Layer BPNN Architecture,” *Int. J. Eng. Trends Technol.*, vol. 3, no. 6, pp. 714–717, 2012.

## BIODATA PENULIS



Penulis lahir di Serang pada tanggal 16 Juni 1997. Penulis merupakan anak kedua dari tiga bersaudara. Penulis telah menempuh pendidikan formal di sekolah negeri mulai dari SD Al-Azhar Syifa Budi YPWKS Cilegon, SMPIT Raudhatul Jannah, SMAN 1 Kota Serang. Setelah lulus, penulis melanjutkan ke jenjang perguruan tinggi negeri di Surabaya, yakni Departemen Sistem Informasi Institut Teknologi Sepuluh Nopember Surabaya. Sebagai mahasiswa, penulis aktif dalam urusan kepanitiaan. Tercatat penulis aktif berkontribusi melalui keanggotaan kepanitiaan di acara YES SUMMIT tahun 2015 sebagai Staf Administrasi dan pada tahun kepengurusan 2016 sebagai Koordinator Divisi Administrasi. Penulis pernah melakukan kerja praktik di Departemen Pengelolaan Sistem Informasi Bank Indonesia, Surabaya pada bulan Juni hingga Juli tahun 2017. Untuk mendapatkan gelar Sarjana Komputer (S.Kom), penulis mengambil laboratorium Rekayasa Data dan Intelejensi Bisnis dengan topik tugas akhir Klasifikasi menggunakan *Artificial Neural Network* pada variabilitas denyut jantung. Untuk kepentingan penelitian penulis juga dapat dihubungi melalui e-mail: [fianaw@gmail.com](mailto:fianaw@gmail.com).

*(Halaman ini sengaja dikosongkan)*

**LAMPIRAN A**  
**HASIL KLASIFIKASI HIGHER-ORDER MOMENTS**  
**DETRENDED FLUCTUATION ANALYSIS**  
**PERCOBAAN 1**

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
2	0,1	0.5	69.05%	0.00	0.69	0.82
		0.6	69.40%	0.00	0.69	0.81
		0.7	69.75%	0.00	0.70	0.80
		0.8	68.84%	0.00	0.69	0.79
		0.9	71.58%	0.00	0.72	0.80
	0,2	0.5	69.75%	0.00	0.70	0.80
		0.6	70.18%	0.00	0.70	0.80
		0.7	71.16%	0.00	0.71	0.78
		0.8	71.44%	0.00	0.71	0.79
		0.9	69.33%	0.00	0.69	0.74
	0,3	0.5	69.89%	0.00	0.70	0.79
		0.6	71.93%	0.00	0.72	0.78
		0.7	70.81%	0.00	0.71	0.79
		0.8	66.88%	0.00	0.67	0.78
		0.9	67.16%	0.00	0.67	0.53
	0,4	0.5	71.58%	0.00	0.72	0.78
		0.6	71.93%	0.00	0.72	0.79
		0.7	68.49%	0.67	0.69	0.73
		0.8	66.95%	0.00	0.67	0.54
		0.9	67.16%	0.00	0.67	0.53
	0,5	0.5	70.95%	0.00	0.71	0.77
		0.6	67.23%	0.00	0.67	0.54
		0.7	66.88%	0.00	0.67	0.78

A-2

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
3	0.6	0.8	66.81%	0.00	0.67	0.56
		0.9	66.81%	0.00	0.67	0.45
	0.6	0.5	70.39%	0.71	0.70	0.77
		0.6	66.88%	0.51	0.67	0.78
		0.7	67.09%	0.00	0.67	0.53
		0.8	66.81%	0.00	0.67	0.59
		0.9	66.81%	0.00	0.67	0.41
	0.7	0.5	66.88%	0.00	0.67	0.77
		0.6	69.54%	0.00	0.70	0.76
		0.7	67.09%	0.00	0.67	0.50
		0.8	66.88%	0.00	0.67	0.73
		0.9	66.81%	0.00	0.67	0.46
	0.8	0.5	68.28%	0.00	0.68	0.73
		0.6	68.91%	0.69	0.69	0.81
		0.7	67.23%	0.00	0.67	0.54
		0.8	66.81%	0.00	0.67	0.70
		0.9	66.81%	0.00	0.67	0.38
	0.9	0.5	69.47%	0.00	0.70	0.76
		0.6	66.81%	0.00	0.67	0.71
		0.7	66.81%	0.00	0.67	0.73
		0.8	67.30%	0.00	0.67	0.54
		0.9	66.81%	0.00	0.67	0.41
	0,1	0.5	70.67%	0.67	0.71	0.79
		0.6	70.67%	0.67	0.71	0.79
		0.7	70.74%	0.69	0.71	0.81
		0.8	69.96%	0.62	0.70	0.80
		0.9	70.39%	0.00	0.70	0.77
		0.2	0.5	69.82%	0.66	0.70

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
0.3	0.6	0.6	69.05%	0.69	0.69	0.73
		0.7	70.04%	0.00	0.70	0.76
		0.8	71.86%	0.62	0.72	0.76
		0.9	67.02%	0.00	0.67	0.73
	0.7	0.5	70.32%	0.71	0.70	0.80
		0.6	71.58%	0.67	0.72	0.77
		0.7	69.96%	0.00	0.70	0.75
		0.8	69.61%	0.70	0.70	0.79
		0.9	66.81%	0.00	0.67	0.54
	0.8	0.5	71.58%	0.64	0.72	0.77
		0.6	70.39%	0.00	0.70	0.77
		0.7	67.30%	0.00	0.67	0.76
		0.8	69.96%	0.00	0.70	0.73
		0.9	66.95%	0.00	0.67	0.45
	0.9	0.5	71.93%	0.00	0.72	0.76
		0.6	71.44%	0.00	0.71	0.75
		0.7	66.81%	0.00	0.67	0.75
		0.8	67.02%	0.00	0.67	0.46
		0.9	66.81%	0.00	0.67	0.52
	0.4	0.5	68.63%	0.00	0.69	0.77
		0.6	70.25%	0.71	0.70	0.75
		0.7	69.75%	0.70	0.70	0.71
		0.8	66.81%	0.00	0.67	0.67
		0.9	66.81%	0.00	0.67	0.40
	0.5	0.5	66.81%	0.00	0.67	0.78
		0.6	66.95%	0.67	0.67	0.75
		0.7	68.56%	0.53	0.69	0.74
		0.8	66.81%	0.00	0.67	0.67

A-4

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
4	0.8	0.9	66.81%	0.00	0.67	0.58
		0.5	67.02%	0.60	0.67	0.78
		0.6	66.88%	0.00	0.67	0.51
		0.7	67.02%	0.00	0.67	0.08
		0.8	66.81%	0.00	0.67	0.71
		0.9	66.81%	0.00	0.67	0.38
	0.9	0.5	67.09%	0.57	0.67	0.77
		0.6	67.02%	0.59	0.67	0.55
		0.7	66.81%	0.00	0.67	0.74
		0.8	67.02%	0.00	0.67	0.51
		0.9	66.81%	0.00	0.67	0.46
	0.1	0.5	70.60%	0.67	0.71	0.77
		0.6	70.11%	0.65	0.70	0.77
		0.7	72.07%	0.71	0.72	0.80
		0.8	70.32%	0.70	0.70	0.78
		0.9	71.72%	0.66	0.72	0.76
	0.2	0.5	70.18%	0.66	0.70	0.79
		0.6	69.82%	0.68	0.70	0.79
		0.7	71.30%	0.73	0.71	0.77
		0.8	70.29%	0.65	0.70	0.76
		0.9	70.04%	0.00	0.70	0.80
	0.3	0.5	70.60%	0.72	0.71	0.77
		0.6	69.96%	0.65	0.70	0.79
		0.7	69.19%	0.62	0.69	0.78
		0.8	69.89%	0.00	0.70	0.80
		0.9	66.67%	0.00	0.67	0.73
	0.4	0.5	70.11%	0.63	0.70	0.78
		0.6	69.61%	0.66	0.70	0.80

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
	0.5	0.7	71.02%	0.00	0.71	0.76
		0.8	69.54%	0.00	0.70	0.78
		0.9	66.81%	0.00	0.67	0.45
		0.5	69.19%	0.65	0.69	0.78
		0.6	70.60%	0.72	0.71	0.74
	0.6	0.7	67.16%	0.64	0.67	0.79
		0.8	67.02%	0.00	0.67	0.54
		0.9	66.81%	0.00	0.67	0.58
		0.5	60.60%	0.69	0.79	0.69
		0.6	69.33%	0.69	0.69	0.75
	0.7	0.7	66.95%	0.59	0.67	0.78
		0.8	67.02%	0.61	0.67	0.59
		0.9	67.09%	0.64	0.67	0.47
		0.5	70.39%	0.00	0.70	0.74
		0.6	70.53%	0.00	0.71	0.79
	0.8	0.7	67.02%	0.65	0.67	0.77
		0.8	66.81%	0.00	0.67	0.57
		0.9	66.81%	0.00	0.67	0.48
		0.5	69.12%	0.62	0.69	0.75
		0.6	66.88%	0.00	0.67	0.78
	0.9	0.7	67.02%	0.60	0.67	0.55
		0.8	66.81%	0.00	0.67	0.50
		0.9	66.81%	0.00	0.67	0.39
		0.5	67.02%	0.00	0.67	0.75
		0.6	69.82%	0.58	0.70	0.75
		0.7	67.09%	0.00	0.67	0.45
		0.8	69.33%	0.00	0.69	0.66
		0.9	66.81%	0.00	0.67	0.46

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
16	0,1	0.5	70.81%	0.66	0.71	0.79
		0.6	70.53%	0.66	0.71	0.75
		0.7	70.11%	0.66	0.70	0.73
		0.8	70.32%	0.65	0.70	0.76
		0.9	70.18%	0.67	0.70	0.73
	0,2	0.5	69.82%	0.65	0.70	0.77
		0.6	69.68%	0.65	0.70	0.72
		0.7	70.46%	0.67	0.71	0.76
		0.8	69.61%	0.64	0.70	0.73
		0.9	67.30%	0.61	0.67	0.74
	0,3	0.5	70.53%	0.65	0.71	0.75
		0.6	70.32%	0.66	0.70	0.74
		0.7	70.32%	0.65	0.70	0.74
		0.8	69.61%	0.00	0.70	0.75
		0.9	67.09%	0.65	0.67	0.76
	0,4	0.5	69.05%	0.62	0.69	0.74
		0.6	68.70%	0.61	0.69	0.74
		0.7	71.65%	0.71	0.72	0.77
		0.8	69.19%	0.63	0.69	0.77
		0.9	67.65%	0.73	0.68	0.61
	0,5	0.5	69.75%	0.66	0.70	0.74
		0.6	67.79%	0.65	0.68	0.77
		0.7	70.46%	0.67	0.71	0.78
		0.8	68.77%	0.59	0.69	0.77
		0.9	66.81%	0.45	0.67	0.66
	0,6	0.5	68.98%	0.63	0.69	0.76
		0.6	68.49%	0.65	0.69	0.75
		0.7	69.61%	0.62	0.70	0.74

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
20	0.7	0.8	70.53%	0.69	0.71	0.71
		0.9	67.09%	0.00	0.67	0.56
		0.5	71.44%	0.71	0.71	0.72
		0.6	69.68%	0.64	0.70	0.76
		0.7	70.53%	0.68	0.71	0.77
		0.8	67.02%	0.70	0.67	0.70
		0.9	66.74%	0.00	0.67	0.54
	0.8	0.5	69.96%	0.64	0.70	0.78
		0.6	70.32%	0.68	0.70	0.68
		0.7	68.77%	0.61	0.69	0.77
		0.8	66.88%	0.00	0.67	0.47
		0.9	66.81%	0.00	0.67	0.50
	0.9	0.5	69.05%	0.62	0.69	0.76
		0.6	66.88%	0.00	0.67	0.59
		0.7	68.63%	0.00	0.69	0.73
		0.8	69.12%	0.00	0.69	0.74
		0.9	66.81%	0.00	0.67	0.38
	0,1	0.5	69.54%	0.65	0.70	0.72
		0.6	68.98%	0.64	0.69	0.72
		0.7	70.04%	0.65	0.70	0.72
		0.8	70.39%	0.66	0.70	0.73
		0.9	71.23%	0.67	0.71	0.72
	0.2	0.5	68.70%	0.63	0.69	0.71
		0.6	68.70%	0.64	0.69	0.74
		0.7	68.42%	0.62	0.68	0.75
		0.8	68.77%	0.62	0.69	0.74
		0.9	69.96%	0.70	0.70	0.73
		0.3	0.5	69.82%	0.64	0.70

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
0.4	0.6	0.6	68.56%	0.62	0.69	0.73
		0.7	68.84%	0.61	0.69	0.75
		0.8	68.84%	0.64	0.69	0.77
		0.9	68.63%	0.66	0.69	0.71
	0.4	0.5	68.14%	0.61	0.68	0.74
		0.6	69.26%	0.63	0.69	0.72
		0.7	68.14%	0.59	0.68	0.73
		0.8	67.02%	0.65	0.67	0.77
		0.9	70.18%	0.00	0.70	0.73
	0.5	0.5	68.28%	0.64	0.68	0.75
		0.6	70.74%	0.67	0.71	0.75
		0.7	69.89%	0.61	0.70	0.76
		0.8	66.81%	0.56	0.67	0.71
		0.9	66.95%	0.00	0.67	0.65
	0.6	0.5	71.58%	0.68	0.72	0.75
		0.6	70.74%	0.67	0.71	0.74
		0.7	68.91%	0.62	0.69	0.76
		0.8	66.81%	0.00	0.67	0.67
		0.9	66.81%	0.00	0.67	0.51
	0.7	0.5	70.46%	0.71	0.71	0.76
		0.6	67.86%	0.61	0.68	0.76
		0.7	67.09%	0.65	0.67	0.77
		0.8	70.11%	0.71	0.70	0.66
		0.9	66.81%	0.00	0.67	0.67
	0.8	0.5	68.42%	0.63	0.68	0.72
		0.6	69.40%	0.67	0.69	0.68
		0.7	70.18%	0.70	0.70	0.68
		0.8	66.74%	0.00	0.67	0.59

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
0.9	0.9	66.81%	0.00	0.67	0.38	
	0.5	68.91%	0.61	0.69	0.76	
	0.6	67.72%	0.60	0.68	0.75	
	0.7	66.74%	0.00	0.67	0.75	
	0.8	66.81%	0.00	0.67	0.63	
	0.9	66.81%	0.00	0.67	0.55	



**LAMPIRAN B**  
**HASIL KLASIFIKASI HIGHER-ORDER MOMENTS**  
**DETRENDED FLUCTUATION ANALYSIS**  
**PERCOBAAN 2**

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
2	0,1	0.5	69.05%	0.64	0.69	0.80
		0.6	68.76%	0.64	0.69	0.80
		0.7	69.24%	0.69	0.69	0.79
		0.8	67.90%	0.74	0.68	0.78
		0.9	70.67%	0.00	0.71	0.75
	0,2	0.5	69.24%	0.74	0.69	0.78
		0.6	68.76%	0.74	0.69	0.78
		0.7	67.33%	0.00	0.67	0.79
		0.8	70.19%	0.69	0.70	0.76
		0.9	70.10%	0.00	0.70	0.78
	0,3	0.5	67.24%	0.00	0.67	0.79
		0.6	69.33%	0.69	0.69	0.79
		0.7	68.10%	0.00	0.68	0.79
		0.8	67.90%	0.74	0.68	0.78
		0.9	70.10%	0.55	0.70	0.66
	0,4	0.5	67.43%	0.00	0.67	0.79
		0.6	68.29%	0.00	0.68	0.79
		0.7	68.48%	0.00	0.69	0.78
		0.8	68.48%	0.00	0.69	0.74
		0.9	66.95%	0.00	0.67	0.72
	0,5	0.5	67.33%	0.66	0.67	0.78
		0.6	66.57%	0.00	0.67	0.79

B-2

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC	
3	0.1	0.7	69.43%	0.00	0.69	0.80	
		0.8	68.00%	0.00	0.68	0.77	
		0.9	70.38%	0.00	0.70	0.66	
		0.6	0.5	66.86%	0.00	0.67	0.79
			0.6	66.95%	0.00	0.67	0.78
			0.7	67.24%	0.00	0.67	0.71
			0.8	66.95%	0.53	0.67	0.68
			0.9	68.67%	0.00	0.69	0.66
			0.5	67.62%	0.00	0.68	0.76
			0.6	67.43%	0.64	0.67	0.78
		0.7	0.7	69.33%	0.00	0.69	0.69
			0.8	67.52%	0.00	0.68	0.71
			0.9	67.33%	0.00	0.67	0.39
		0.8	0.5	66.38%	0.00	0.66	0.76
			0.6	69.05%	0.00	0.69	0.69
			0.7	68.48%	0.00	0.69	0.72
			0.8	67.43%	0.00	0.67	0.64
			0.9	67.33%	0.00	0.67	0.48
		0.9	0.5	72.48%	0.70	0.73	0.77
			0.6	72.19%	0.69	0.72	0.77
			0.7	68.19%	0.00	0.68	0.69
			0.8	66.38%	0.00	0.66	0.67
			0.9	67.43%	0.00	0.67	0.50
		3	0.5	72.10%	0.70	0.72	0.79
			0.6	71.43%	0.68	0.71	0.78
			0.7	70.76%	0.68	0.71	0.77
			0.8	70.38%	0.66	0.70	0.79

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
	0.2	0.9	69.62%	0.66	0.70	0.76
		0.5	69.24%	0.65	0.69	0.75
		0.6	69.52%	0.66	0.70	0.79
		0.7	69.14%	0.64	0.69	0.77
		0.8	69.43%	0.66	0.69	0.77
		0.9	70.95%	0.67	0.71	0.78
	0.3	0.5	69.71%	0.65	0.70	0.78
		0.6	70.67%	0.66	0.71	0.77
		0.7	68.29%	0.62	0.68	0.76
		0.8	65.90%	0.67	0.66	0.75
		0.9	67.90%	0.00	0.68	0.69
	0.4	0.5	69.81%	0.65	0.70	0.78
		0.6	70.10%	0.73	0.70	0.80
		0.7	68.19%	0.67	0.68	0.78
		0.8	69.62%	0.74	0.70	0.76
		0.9	69.81%	0.00	0.70	0.67
	0.5	0.5	68.95%	0.65	0.69	0.75
		0.6	67.43%	0.67	0.67	0.75
		0.7	68.67%	0.65	0.69	0.76
		0.8	67.14%	0.53	0.67	0.75
		0.9	70.76%	0.64	0.71	0.67
	0.6	0.5	68.67%	0.74	0.69	0.79
		0.6	69.05%	0.00	0.69	0.77
		0.7	69.62%	0.68	0.70	0.77
		0.8	66.95%	0.00	0.67	0.73
		0.9	68.19%	0.53	0.68	0.65

B-4

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
4	0.7	0.5	70.48%	0.67	0.71	0.77
		0.6	69.05%	0.64	0.69	0.77
		0.7	67.05%	0.00	0.67	0.72
		0.8	68.19%	0.00	0.68	0.74
		0.9	68.67%	0.71	0.69	0.64
	0.8	0.5	69.81%	0.69	0.70	0.76
		0.6	68.86%	0.00	0.69	0.78
		0.7	69.62%	0.00	0.70	0.67
		0.8	67.43%	0.74	0.67	0.68
		0.9	67.33%	0.00	0.67	0.40
	0.9	0.5	68.19%	0.00	0.68	0.77
		0.6	67.14%	0.00	0.67	0.71
		0.7	67.81%	0.00	0.68	0.72
		0.8	68.38%	0.74	0.68	0.72
		0.9	67.43%	0.00	0.67	0.39
	0.1	0.5	70.86%	0.67	0.71	0.78
		0.6	70.86%	0.67	0.71	0.78
		0.7	70.86%	0.68	0.71	0.76
		0.8	70.19%	0.66	0.70	0.78
		0.9	68.76%	0.63	0.69	0.76
	0.2	0.5	70.48%	0.66	0.71	0.78
		0.6	70.86%	0.67	0.71	0.76
		0.7	71.14%	0.68	0.71	0.77
		0.8	70.29%	0.65	0.70	0.76
		0.9	69.62%	0.66	0.70	0.76
	0.3	0.5	72.38%	0.71	0.72	0.78
		0.6	68.67%	0.64	0.69	0.78

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
0.4	0.7	0.7	68.57%	0.63	0.69	0.78
		0.8	68.57%	0.59	0.69	0.76
		0.9	70.19%	0.71	0.70	0.71
	0.6	0.5	68.29%	0.62	0.68	0.78
		0.6	70.57%	0.67	0.71	0.77
		0.7	68.00%	0.61	0.68	0.76
		0.8	70.95%	0.68	0.71	0.78
		0.9	70.95%	0.71	0.71	0.63
	0.5	0.5	70.10%	0.67	0.70	0.78
		0.6	66.86%	0.74	0.67	0.77
		0.7	67.90%	0.63	0.68	0.77
		0.8	71.81%	0.69	0.72	0.73
		0.9	70.29%	0.71	0.70	0.61
	0.6	0.5	68.38%	0.74	0.68	0.77
		0.6	66.76%	0.70	0.67	0.77
		0.7	66.76%	0.64	0.67	0.76
		0.8	67.62%	0.00	0.68	0.73
		0.9	67.52%	0.68	0.68	0.57
	0.7	0.5	69.90%	0.65	0.70	0.77
		0.6	68.19%	0.00	0.68	0.73
		0.7	70.67%	0.68	0.71	0.73
		0.8	65.14%	0.74	0.65	0.70
		0.9	67.43%	0.00	0.67	0.44
	0.8	0.5	67.43%	0.62	0.67	0.77
		0.6	69.43%	0.00	0.69	0.76
		0.7	66.19%	0.00	0.66	0.73

Jumlah Node Pada Hidden Layer	Learning Rate	Momentum	Accuracy	Precision	Recall	ROC
16	0.9	0.8	65.33%	0.54	0.65	0.68
		0.9	67.33%	0.00	0.67	0.47
		0.5	67.33%	0.00	0.67	0.74
		0.6	68.19%	0.00	0.68	0.75
		0.7	65.52%	0.74	0.66	0.75
		0.8	67.33%	0.00	0.67	0.70
		0.9	67.33%	0.00	0.67	0.43
	0.1	0.5	70.76%	0.67	0.71	0.75
		0.6	70.00%	0.65	0.70	0.74
		0.7	69.81%	0.65	0.70	0.72
		0.8	71.33%	0.67	0.71	0.74
		0.9	72.10%	0.70	0.72	0.74
	0.2	0.5	70.38%	0.66	0.70	0.74
		0.6	70.76%	0.66	0.71	0.71
		0.7	70.29%	0.66	0.70	0.75
		0.8	69.33%	0.62	0.69	0.73
		0.9	72.67%	0.70	0.73	0.76
	0.3	0.5	68.76%	0.63	0.69	0.71
		0.6	69.90%	0.64	0.70	0.72
		0.7	70.48%	0.66	0.71	0.71
		0.8	71.33%	0.68	0.71	0.77
		0.9	67.33%	0.00	0.67	0.42
	0.4	0.5	70.19%	0.65	0.70	0.72
		0.6	69.62%	0.65	0.70	0.74
		0.7	70.57%	0.66	0.71	0.74
		0.8	72.10%	0.69	0.72	0.78
		0.9	67.90%	0.00	0.68	0.60

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
	0.5	0.5	71.33%	0.68	0.71	0.74
		0.6	71.14%	0.67	0.71	0.73
		0.7	68.38%	0.63	0.68	0.75
		0.8	70.86%	0.67	0.71	0.71
		0.9	12.29%	0.00	0.12	0.39
	0.6	0.5	72.29%	0.70	0.72	0.75
		0.6	71.71%	0.68	0.72	0.76
		0.7	72.29%	0.70	0.72	0.74
		0.8	71.43%	0.69	0.71	0.75
		0.9	68.76%	0.69	0.69	0.64
	0.7	0.5	68.38%	0.63	0.68	0.73
		0.6	68.95%	0.63	0.69	0.76
		0.7	69.90%	0.67	0.70	0.71
		0.8	70.86%	0.69	0.71	0.66
		0.9	12.29%	0.00	0.12	0.44
	0.8	0.5	71.24%	0.68	0.71	0.75
		0.6	70.76%	0.67	0.71	0.74
		0.7	70.67%	0.68	0.71	0.73
		0.8	68.48%	0.62	0.69	0.58
		0.9	68.67%	0.00	0.69	0.67
	0.9	0.5	66.86%	0.63	0.67	0.73
		0.6	71.24%	0.68	0.71	0.72
		0.7	70.38%	0.76	0.70	0.65
		0.8	20.48%	0.16	0.21	0.57
		0.9	67.33%	0.00	0.67	0.57
20	0,1	0.5	70.10%	0.65	0.69	0.71

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
	0.6	0.6	68.76%	0.65	0.69	0.71
		0.7	70.29%	0.66	0.70	0.68
		0.8	69.05%	0.64	0.69	0.73
		0.9	69.24%	0.63	0.69	0.73
	0.2	0.5	70.38%	0.66	0.70	0.76
		0.6	69.43%	0.65	0.69	0.72
		0.7	69.81%	0.65	0.70	0.73
		0.8	71.43%	0.68	0.71	0.72
		0.9	70.38%	0.72	0.70	0.71
	0.3	0.5	71.24%	0.67	0.71	0.74
		0.6	69.90%	0.66	0.70	0.74
		0.7	70.57%	0.67	0.71	0.72
		0.8	70.38%	0.67	0.70	0.70
		0.9	68.67%	0.63	0.69	0.58
	0.4	0.5	69.43%	0.65	0.69	0.73
		0.6	69.90%	0.65	0.70	0.74
		0.7	70.38%	0.66	0.70	0.75
		0.8	66.76%	0.64	0.67	0.74
		0.9	70.38%	0.65	0.70	0.71
	0.5	0.5	70.29%	0.66	0.70	0.72
		0.6	70.00%	0.65	0.70	0.73
		0.7	69.52%	0.66	0.70	0.72
		0.8	70.86%	0.69	0.71	0.73
		0.9	67.52%	0.78	0.68	0.60
	0.6	0.5	71.14%	0.67	0.71	0.75
		0.6	70.57%	0.66	0.71	0.70
		0.7	72.29%	0.69	0.72	0.73

Jumlah Node Pada Hidden Layer	<i>Learning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	ROC
		0.8	66.00%	0.55	0.66	0.69
		0.9	67.52%	0.78	0.68	0.39
	0.7	0.5	67.62%	0.63	0.68	0.69
		0.6	70.86%	0.67	0.71	0.69
		0.7	72.67%	0.70	0.73	0.72
		0.8	68.19%	0.00	0.68	0.59
		0.9	11.81%	0.23	0.12	0.51
	0.8	0.5	72.57%	0.70	0.73	0.71
		0.6	66.00%	0.62	0.66	0.76
		0.7	68.86%	0.62	0.69	0.58
		0.8	68.76%	0.00	0.69	0.53
		0.9	67.43%	0.00	0.67	0.40
	0.9	0.5	71.52%	0.68	0.72	0.72
		0.6	70.95%	0.67	0.71	0.73
		0.7	67.62%	0.63	0.68	0.73
		0.8	71.33%	0.70	0.71	0.65
		0.9	67.33%	0.00	0.67	0.46