



TUGAS AKHIR - KS141501

**KLASIFIKASI PROGNOSIS PASIEN ICU  
MENGUNAKAN ARTIFICIAL NEURAL NETWORK  
(ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-  
ORDER MOMENTS DETRENDED FLUCTUATION  
ANALYSIS**

*PROGNOSIS CLASSIFICATION OF ICU PATIENTS  
USING ARTIFICIAL NEURAL NETWORK (ANN)  
BASED ON HIGHER-ORDER MOMENTS DETRENDED  
FLUCTUATION ANALYSIS FEATURE EXTRACTION*

FANNY ISTIFADAH  
NRP 0521144000089

Dosen Pembimbing  
Edwin Riksakomara, S.Kom, M.T  
Faizal Mahananto, S.Kom, M.Eng, Ph.D

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

**TUGAS AKHIR - KS141501**

**KLASIFIKASI PROGNOSIS PASIEN ICU  
MENGUNAKAN ARTIFICIAL NEURAL NETWORK  
(ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-  
ORDER MOMENTS DETRENDED FLUCTUATION  
ANALYSIS**

**FANNY ISTIFADAH**

**NRP 05211440000089**

**Dosen Pembimbing**

**Edwin Riksakomara, S.Kom, M.T**

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

**FINAL PROJECT - KS141501**

***PROGNOSIS CLASSIFICATION OF ICU  
PATIENTS USING ARTIFICIAL NEURAL  
NETWORK (ANN) BASED ON HIGHER-ORDER  
MOMENTS DETRENDED FLUCTUATION  
ANALYSIS FEATURE EXTRACTION***

**FANNY ISTIFADAH**

**NRP 05211440000089**

**Supervisors**

**Edwin Riksakomara, S.Kom, M.T**

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



**LEMBAR PENGESAHAN**

**KLASIFIKASI PROGNOSIS PASIEN ICU  
MENGUNAKAN ARTIFICIAL NEURAL NETWORK  
(ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER-  
ORDER MOMENTS DETRENDED FLUCTUATION  
ANALYSIS**

**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:

**FANNY ISTIFADAH**  
NRP. 05211440000089

Surabaya, Juli 2018

**KEPALA  
DEPARTEMEN SISTEM INFORMASI**

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

## LEMBAR PERSETUJUAN

### KLASIFIKASI PROGNOSIS PASIEN ICU MENGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER- ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS

#### TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer  
pada

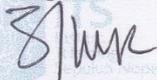
Departemen Sistem Informasi  
Fakultas Teknologi Informasi dan Komunikasi  
Institut Teknologi Sepuluh Nopember

Oleh:

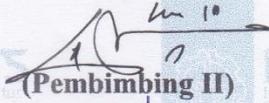
**FANNY ISTIFADAH**  
NRP. 0521144000089

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

**Edwin Riksakomara, S.Kom, M.T**

  
(Pembimbing I)

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

  
(Pembimbing II)

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

  
(Penguji I)

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

**KLASIFIKASI PROGNOSIS PASIEN ICU  
MENGUNAKAN ARTIFICIAL NEURAL  
NETWORK (ANN) BERDASARKAN EKSTRAKSI  
FITUR HIGHER-ORDER MOMENTS DETRENDED  
FLUCTUATION ANALYSIS**

**Nama Mahasiswa** : Fanny Istifadah  
**NRP** : 0521144000089  
**Departemen** : Sistem Informasi  
**Dosen Pembimbing 1** : Edwin Riksakomara, S.Kom, M.T  
**Dosen Pembimbing 2** : Faizal M., S.Kom, M.Eng, Ph.D

**ABSTRAK**

*ICU merupakan salah satu bagian penting dalam rumah sakit. Di ICU pasien akan dicek kondisi serta prognosinya secara intensif. Prognosis dilakukan untuk memutuskan pengobatan apa yang terbaik bagi pasien sehingga ICU dapat memberikan pelayanan yang lebih baik. Dalam menentukan prognosis pasien, saat ini ahli medis banyak menggunakan bantuan sistem scoring yang memiliki beberapa kekurangan seperti parameter yang diuji banyak, membutuhkan waktu lama, dan tidak merefleksikan kondisi pasien kedepannya. Padahal penilaian prognosis dapat juga dianalisis dengan memanfaatkan sinyal elektrokardiogram yang didapatkan dari bedside monitor ICU. Untuk melakukan analisis prognosis pasien, sinyal elektrokardiogram dikonversi menjadi sinyal Heart Rate Variability (HRV) dengan melakukan perhitungan R-R*

*intervalnya. Kemudian sinyal HRV dilakukan ekstraksi fitur menggunakan Higher-Order Moments Detrended Fluctuation Analysis untuk melihat struktur non-linear dan melihat volatility pada sinyal HRV dengan melakukan perhitungan nilai skewness dan kurtosis. Output dari ekstraksi fitur adalah berupa nilai fungsi fluktuasi dan local scaling eksponent berdasarkan skewness dan kurtosis pada pasien prognosis baik dan buruk. Nilai tersebut kemudian digunakan sebagai input untuk klasifikasi menggunakan Artificial Neural Network. Output dari klasifikasi tersebut adalah klasifikasi prognosis pasien ICU. Hasil klasifikasi ekstraksi fitur HOMDFA menghasilkan model terbaik pada model dengan jumlah scale 5, hidden node 8, learning rate 1, momentum 0,1 dan 0,2. Model tersebut menghasilkan nilai accuracy sebesar 74.19%, sensitifity 0.742, specificity 0.39, dan AUC sebesar 0.681.*

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

***PROGNOSIS CLASSIFICATION OF ICU PATIENTS  
USING ARTIFICIAL NEURAL NETWORK (ANN)  
BASED ON HIGHER-ORDER MOMENTS  
DETRENDED FLUCTUATION ANALYSIS  
FEATURE EXTRACTION***

**Name** : Fanny Istifadah  
**NRP** : 0521144000089  
**Department** : Information Systems  
**Supervisor 1** : Edwin Riksakomara, S.Kom, M.T  
**Supervisor 2** : Faizal M., S.Kom, M.Eng, Ph.D

**ABSTRACT**

*ICU is one important part of the hospital. In the ICU, the patient will be checked for the condition and the prognosis intensively. The prognosis is performed to decide what treatment is best for the patient so that the ICU can provide better services. In determining the patient's prognosis, many medical experts now use scoring systems that have some disadvantages such as many tested parameters, take a long time, and do not reflect the patient's condition going forward. Though the prognosis assessment can also be analyzed by utilizing electrocardiogram signals obtained from bedside ICU monitors. To perform a patient prognosis analysis, the electrocardiogram signal is converted into a Heart Rate Variability (HRV) signal by performing R-R interval. Then HRV signals feature extracted using Higher-Order Moments Detrended Fluctuation Analysis to see non-linear structures and volatility on HRV signals by calculating skewness and kurtosis values. The output of feature*

*extraction is the value of fluctuation function and local scaling exponent based on skewness and kurtosis in patients with good and bad prognosis. The value is then used as an input for classification using the Artificial Neural Network. The output of the classification is the classification of prognosis of ICU patients. the best model of HOMDFA feature extraction classification are model with scale 5, hidden node 8, learning rate 1, momentum 0,1 and 0,2. The model produces accuracy values of 74.19%, sensitivity 0.742, specificity 0.39, and AUC of 0.681.*

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

## **KATA PENGANTAR**

Puji Syukur Kepada Allah SWT karena atas limpahan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan buku tugas akhir dengan judul:

### **KLASIFIKASI PROGNOSIS PASIEN ICU MENGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) BERDASARKAN EKSTRAKSI FITUR HIGHER- ORDER MOMENTS DETRENDED FLUCTUATION ANALYSIS**

yang merupakan satu syarat kelulusan pada Departemen Sistem Informasi, Institut Teknologi Sepuluh Nopember Surabaya.

Penulis ingin mengucapkan terimakasih kepada pihak-pihak yang telah mendukung, memberikan saran, motivasi semangat dan bantuan baik materi maupun spiritual demi tercapainya tujuan pembuatan tugas akhir ini. Maka dari itu, dalam kesempatan ini penulis akan menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Allah SWT, yang telah memberikan kesehatan, kemudahan, kelancaran, dan kesempatan untuk penulis hingga dapat menyelesaikan Tugas Akhir ini.
2. Kedua orangtua, kakak, dan seluruh keluarga yang selalu hadir dan senantiasa mendoakan dan memberikan kasih sayang serta semangat kepada penulis.
3. Bapak Edwin Riksakomara, S.Kom, MT. dan Bapak Faizal M., S.Kom, M.Eng, Ph.D. selaku Dosen Pembimbing yang telah banyak meluangkan waktu untuk membimbing mengarahkan dan mendukung dalam penyelesaian tugas akhir.
4. Ibu Wiwik Anggraeni, S.Si, M.Kom. dan Ibu Eko Wahyu Tyas D, S.Kom, MBA selaku dosen penguji yang telah memberikan masukan kepada penulis untuk perbaikan pengerjaan tugas akhir ini.

5. Ibu Feby Artwodini Muqtadiroh S.Kom., MT. selaku dosen wali yang telah memberikan arahan terkait perkuliahan di Departemen Sistem Informasi
6. Seluruh dosen pengajar beserta staf dan karyawan di Departemen Sistem Informasi, FTIK ITS Surabaya yang telah memberikan ilmu dan bantuan kepada penulis selama 8 semester ini
7. Teman-teman OSIRIS khususnya alden, pras, Adrian, risha, lita, ayusha, dan galih yang telah membantu dan memotivasi penulis sehingga dapat menyelesaikan tugas akhir ini.

Penulis menyadari bahwa Tugas Akhir ini masih belum sempurna dan memiliki banyak kekurangan di dalamnya. Dan oleh karena itu, penulis meminta maaf atas segala kesalahan yang dibuat penulis dalam buku Tugas Akhir ini. Penulis membuka pintu selebar-lebarnya kepada pihak-pihak yang ingin memberikan kritik, saran, masukan, dan penelitian selanjutnya yang ingin menyempurnakan karya, dan Tugas Akhir ini. Semoga buku Tugas Akhir ini bermanfaat bagi seluruh pembaca.

Surabaya, 11 Juli 2018

Fanny Istifadah

## DAFTAR ISI

LEMBAR PENGESAHAN.....	iii
LEMBAR PERSETUJUAN.....	iv
ABSTRAK.....	v
ABSTRACT.....	vii
KATA PENGANTAR .....	ix
DAFTAR ISI.....	xi
DAFTAR GAMBAR .....	xvii
DAFTAR TABEL.....	xix
DAFTAR KODE PROGRAM .....	xxv
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah .....	1
1.2. Perumusan Masalah.....	5
1.3. Batasan Masalah.....	6
1.4. Tujuan Tugas Akhir.....	6
1.5. Manfaat Tugas Akhir.....	7
1.6. Relevansi .....	7
BAB II TINJAUAN PUSTAKA .....	9
2.1. Penelitian Sebelumnya .....	9
2.2. Dasar Teori.....	12
2.2.1. Prognosis .....	12
2.2.2. Elektrokardiogram .....	12
2.2.3. Heart Rate Variability .....	14
2.2.4. Artificial Neural Network .....	15

2.2.5. Higher-Order Moments Detrended Fluctuation Analysis .....	18
2.2.6. Uji Rank Sum Wilcoxon .....	20
2.2.7. Uji Performa .....	21
<b>BAB III METODOLOGI.....</b>	<b>23</b>
3.1. Diagram Metodologi.....	23
3.1.1. Studi Literatur dan Pengumpulan Data .....	24
3.1.2. Praproses Data .....	24
3.1.3. Ekstraksi Fitur Higher-Order Detrended Fluctuation Analysis .....	25
3.1.4. Uji Signifikansi .....	25
3.1.5. Klasifikasi ANN.....	25
3.1.6. Penarikan Kesimpulan .....	27
3.1.7. Penyusunan Tugas Akhir .....	27
<b>BAB IV PERANCANGAN .....</b>	<b>29</b>
4.1. Pengumpulan Data.....	29
4.2. Praproses Data .....	30
4.2.1. Pengelompokan Data .....	30
4.2.2. Konversi Sinyal EKG menjadi HRV.....	30
4.2.3. Pemilihan Data.....	31
4.3. Perancangan Model Higher-Order Moments Detrended Fluctuation Analysis .....	31
4.3.1. Perhitungan Integrasi Time Series .....	32
4.3.2. Pembagian Segmen Data.....	32
4.3.3. Perhitungan Nilai Skewness dan Kurtosis ....	33

4.3.4.	Perhitungan Fungsi Fluktuasi.....	34
4.3.5.	Perhitungan Local Scaling Exponent .....	35
4.4.	Perhitungan Parameter Input .....	35
4.4.1.	Pembagian Data .....	36
4.4.2.	Perhitungan Parameter Fungsi Fluktuasi berdasarkan Skewness .....	36
4.4.3.	Perhitungan Parameter Fungsi Fluktuasi berdasarkan Kurtosis.....	36
4.4.4.	Perhitungan Parameter <i>Local Scaling Exponent</i> berdasarkan Skewness .....	37
4.4.5.	Perhitungan Parameter <i>Local Scaling Exponent</i> berdasarkan Kurtosis.....	37
4.5.	Uji Signifikansi.....	37
4.5.1.	Uji Signifikansi Parameter Fungsi Fluktuasi berdasarkan Skewness .....	38
4.5.2.	Uji Signifikansi Parameter Fungsi Fluktuasi berdasarkan Kurtosis.....	38
4.5.3.	Uji Signifikansi Parameter <i>Local Scaling Exponent</i> berdasarkan Skewness.....	39
4.5.4.	Uji Signifikansi Parameter <i>Local Scaling Exponent</i> berdasarkan Kurtosis.....	39
4.6.	Klasifikasi ANN .....	40
4.6.1.	Pemodelan ANN .....	40
4.6.2.	Pelatihan Model .....	43
4.6.3.	Pengujian Model .....	43
4.6.4.	Uji Performa .....	43
BAB V	IMPLEMENTASI .....	45

5.1. Pra Processing Data .....	45
5.1.1. Menambahkan File Anotasi .....	46
5.1.2. Mengubah Sinyal EKG menjadi HRV .....	47
5.2. Pemilihan Data .....	48
5.3. Implementasi Higher-Order Moments Detrended Fluctuation Analysis .....	48
5.3.1. Menghitung Integrasi Time Series .....	48
5.3.2. Membagi Segmen .....	49
5.3.3. Menghitung Nilai <i>Skewness</i> dan <i>Kurtosis</i> ....	51
5.3.4. Menghitung Fungsi Fluktuasi berdasarkan <i>Skewness</i> dan <i>Kurtosis</i> .....	52
5.3.5. Menghitung Local Scaling Exponent berdasarkan <i>Skewness</i> dan <i>Kurtosis</i> .....	53
5.4. Menghitung Parameter Input .....	54
5.4.1. Perhitungan Parameter Fungsi Fluktuasi berdasarkan <i>Skewness</i> .....	54
5.4.2. Perhitungan Parameter Fungsi Fluktuasi berdasarkan <i>Kurtosis</i> .....	55
5.4.3. Perhitungan Parameter <i>Local Scaling Exponent</i> berdasarkan <i>Skewness</i> .....	55
5.4.4. Perhitungan Parameter <i>Local Scaling Exponent</i> berdasarkan <i>Kurtosis</i> .....	56
5.5. Uji Coba Model Higher-Order Moments Detrended Fluctuation Analysis .....	57
5.6. Uji Signifikansi.....	57
5.7. Implementasi Klasifikasi ANN.....	59
5.7.1. Klasifikasi ANN.....	60

5.7.2. Uji Performa .....	61
<b>BAB VI HASIL DAN PEMBAHASAN .....</b>	<b>63</b>
6.1. Hasil Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis.....	63
6.2. Hasil Uji Signifikansi .....	72
6.2.1. Uji Signifikansi Data dengan Scale 5 .....	73
6.2.2. Uji Signifikansi Data dengan Scale 10.....	76
6.2.3. Uji Signifikansi Data dengan Scale 15.....	79
6.2.4. Uji Signifikansi Data dengan Scale 20.....	82
6.2.5. Uji Signifikansi Data dengan Scale 25.....	85
6.2.6. Uji Signifikansi Data dengan Scale 30.....	88
6.3. Hasil Klasifikasi ANN.....	91
6.3.1. Hasil Klasifikasi ANN dengan Scale 5 .....	91
6.3.2. Hasil Klasifikasi ANN dengan Scale 10 .....	92
6.3.3. Hasil Klasifikasi ANN dengan Scale 15 .....	93
6.3.4. Hasil Klasifikasi ANN dengan Scale 20 .....	94
6.3.5. Hasil Klasifikasi ANN Scale 25.....	95
6.3.6. Hasil Klasifikasi ANN Scale 30.....	96
6.4. Hasil Uji Performa.....	96
6.4.1. Hasil Uji Performa Klasifikasi ANN dengan Scale 5 .....	97
6.4.2. Hasil Uji Performa Klasifikasi ANN dengan Scale 10 .....	103
6.4.3. Hasil Uji Performa Klasifikasi ANN dengan Scale 15 .....	109

6.4.4. Hasil Uji Performa Klasifikasi ANN dengan Scale 20.....	114
6.4.5. Hasil Uji Performa Klasifikasi ANN dengan Scale 25.....	120
6.4.6. Hasil Uji Performa Klasifikasi ANN dengan Scale 30.....	126
6.5. Kesimpulan Percobaan .....	132
<b>BAB VII KESIMPULAN DAN SARAN .....</b>	<b>137</b>
7.1. Kesimpulan.....	137
7.2. Saran .....	138
<b>DAFTAR PUSTAKA .....</b>	<b>139</b>
<b>BIODATA PENULIS .....</b>	<b>143</b>
LAMPIRAN A .....	A-1
LAMPIRAN B.....	B-1
LAMPIRAN C.....	C-1
LAMPIRAN D .....	D-1
LAMPIRAN E.....	E-1
LAMPIRAN F .....	F-1
LAMPIRAN G .....	G-1
LAMPIRAN H .....	H-1
LAMPIRAN I.....	I-1
LAMPIRAN J.....	J-1
LAMPIRAN K .....	K-1
LAMPIRAN L.....	L-1

## DAFTAR GAMBAR

Gambar 1.1 Plot Fungsi Fluktuasi Skewness untuk (a) CHF1, (b) CHF2, (c) Normal.....	3
Gambar 1.2 Plot Fungsi Fluktuasi Kurtosis untuk (a) CHF1, (b)CHF2, (c)Normal.....	4
Gambar 2.1 Sinyal Elektrokardiogram .....	13
Gambar 2.2 R-R Interval pada Sinyal EKG .....	15
Gambar 2.3 Multilayer ANN.....	17
Gambar 3.1 Diagram Metodologi Uraian Metodologi.....	23
Gambar 4.1 Struktur Model ANN .....	42
Gambar 5.1 Konfigurasi WEKA .....	61
Gambar 5.2 Contoh Hasil Uji Performa WEKA .....	62
Gambar 6.1 R-R Interval dan Random Walk pada Pasien Prognosis Baik .....	64
Gambar 6.2 R-R Interval dan Random Walk pada Pasien Prognosis Buruk.....	64
Gambar 6.3 Fungsi Fluktuasi berdasarkan Skewness pada Pasien Prognosis Baik. Nilai rata-rata total = $8,92 \times e - 50$ , Rata-Rata Short Term = $2,01 \times e - 50$ , Rata-Rata Long Term = $1,58 \times e - 50$ .....	65
Gambar 6.4 Fungsi Fluktuasi berdasarkan Skewness Pasien Prognosis Buruk. Rata-Rata Total = $2,007 \times e - 46$ , Rata-Rata Short Term = $2,24 \times e - 46$ , Rata-Rata Long Term = $1,77 \times e - 46$ .....	66
Gambar 6.5 Fungsi Fluktuasi berdasarkan Kurtosis Pasien Prognosis Baik. Rata-Rata Total = $8,25 \times e - 66$ , Rata-Rata	

Short Term =  $6,96 \times e - 67$ , Rata-Rata Long Term =  $1,58 \times e - 65$  ..... 67

Gambar 6.6 Fungsi Fluktuasi berdasarkan Kurtosis Pasien Prognosis Buruk. Rata-Rata Total =  $2,41 \times e - 61$ , Rata-Rata Short Term =  $2,7 \times e - 61$ , Rata-Rata Long Term =  $2,12 \times e - 61$  ..... 67

Gambar 6.7 Local Scaling Exponent berdasarkan Skewness Pasien Prognosis Baik. Rata-Rata Total =  $0,9$ , Rata-Rata Short Term =  $0,84$  Rata-Rata Long Term =  $0,96$  ..... 69

Gambar 6.8 Local Scaling Exponent berdasarkan Skewness Pasien Prognosis Buruk. Rata-Rata Total =  $-0,14$ , Rata-Rata Short Term =  $-0,25$  Rata-Rata Long Term =  $-0,033$  ..... 69

Gambar 6.9 Local Scaling Exponent berdasarkan Kurtosis Pasien Prognosis Baik. Rata-Rata Total =  $1,34$ , Rata-Rata Short Term =  $1,3$  Rata-Rata Long Term =  $1,37$  ..... 70

Gambar 6.10 Local Scaling Exponent berdasarkan Kurtosis Pasien Prognosis Buruk. Rata-Rata Total =  $-0,14$ , Rata-Rata Short Term =  $-0,26$  Rata-Rata Long Term =  $-0,03$  ..... 71

## DAFTAR TABEL

Tabel 2.1 Penelitian Sebelumnya .....	9
Tabel 2.2 Komponen EKG .....	13
Tabel 2.3 Tabel Confussion Matrix .....	21
Tabel 4.1 Daftar Nilai Scale .....	33
Tabel 4.2 Hidden Node berdasarkan WEKA.....	41
Tabel 4.3 Rancangan Parameter ANN.....	42
Tabel 5.1 Isi Record File Sinyal EKG .....	45
Tabel 5.2 Isi File Anotasi .....	46
Tabel 5.3 Hasil Konversi Sinyal EKG menjadi HRV .....	47
Tabel 5.4 Skenario Parameter Uji Coba Klasifikasi ANN.....	60
Tabel 6.1 Hasil Uji Signifikansi Parameter Scale 5 .....	73
Tabel 6.2 Hasil Uji Signifikansi Parameter Scale 10 .....	76
Tabel 6.3 Hasil Uji Signifikansi Parameter Scale 15 .....	79
Tabel 6.4 Hasil Uji Signifikansi Parameter Scale 20 .....	82
Tabel 6.5 Hasil Uji Signifikansi Parameter Scale 25 .....	85
Tabel 6.6 Hasil Uji Signifikansi Parameter Scale 30 .....	88
Tabel 6.7 Sebagian Hasil Klasifikasi Scale 10 .....	91
Tabel 6.8 Sebagian Hasil Klasifikasi Scale 10 .....	92
Tabel 6.9 Sebagian Hasil Klasifikasi Scale 15 .....	93
Tabel 6.10 Sebagian Hasil Klasifikasi Scale 20 .....	94
Tabel 6.11 Sebagian Hasil Klasifikasi Scale 25 .....	95
Tabel 6.12 Sebagian Hasil Klasifikasi Scale 30 .....	96

Tabel 6.13 Confusion Matrix dengan Hidden Node 2 pada Data Scale 5 .....	97
Tabel 6.14 Confusion Matrix dengan Hidden Node 3 pada Data Scale 5 .....	98
Tabel 6.15 Confusion Matrix dengan Hidden Node 4 pada Data Scale 5 .....	98
Tabel 6.16 Confusion Matrix dengan Hidden Node 5 pada Data Scale 5 .....	99
Tabel 6.17 Confusion Matrix dengan Hidden Node 6 pada Data Scale 5 .....	99
Tabel 6.18 Confusion Matrix dengan Hidden Node 7 pada Data Scale 5 .....	99
Tabel 6.19 Confusion Matrix dengan Hidden Node 8 pada Data Scale 5 .....	100
Tabel 6.20 Confusion Matrix dengan Hidden Node 9 pada Data Scale 5 .....	100
Tabel 6.21 Confusion Matrix dengan Hidden Node 10 pada Data Scale 5 .....	101
Tabel 6.22 Confusion Matrix dengan Hidden Node 11 pada Data Scale 5 .....	101
Tabel 6.23 Hasil Uji Performa Klasifikasi ANN Scale 5 Epoch 3000 .....	102
Tabel 6.24 Confusion Matrix dengan Hidden Node 2 pada Data Scale 10 .....	103
Tabel 6.25 Confusion Matrix dengan Hidden Node 3 pada Data Scale 10 .....	104
Tabel 6.26 Confusion Matrix dengan Hidden Node 4 pada Data Scale 10 .....	104

Tabel 6.27 Confusion Matrix dengan Hidden Node 5 pada Data Scale 10.....	105
Tabel 6.28 Confusion Matrix dengan Hidden Node 6 pada Data Scale 10.....	105
Tabel 6.29 Confusion Matrix dengan Hidden Node 7 pada Data Scale 10.....	105
Tabel 6.30 Confusion Matrix dengan Hidden Node 8 pada Data Scale 10.....	106
Tabel 6.31 Confusion Matrix dengan Hidden Node 9 pada Data Scale 10.....	106
Tabel 6.32 Confusion Matrix dengan Hidden Node 10 pada Data Scale 10 .....	107
Tabel 6.33 Confusion Matrix dengan Hidden Node 11 pada Data Scale 10 .....	107
Tabel 6.34 Hasil Uji Performa Klasifikasi ANN Scale 10 Epoch 3000 .....	108
Tabel 6.35 Confusion Matrix dengan Hidden Node 2 pada Data Scale 15.....	109
Tabel 6.36 Confusion Matrix dengan Hidden Node 3 pada Data Scale 15.....	109
Tabel 6.37 Confusion Matrix dengan Hidden Node 4 pada Data Scale 15.....	110
Tabel 6.38 Confusion Matrix dengan Hidden Node 5 pada Data Scale 15.....	110
Tabel 6.39 Confusion Matrix dengan Hidden Node 6 pada Data Scale 15.....	111
Tabel 6.40 Confusion Matrix dengan Hidden Node 7 pada Data Scale 15.....	111

Tabel 6.41 Confusion Matrix dengan Hidden Node 8 pada Data Scale 15 .....	112
Tabel 6.42 Confusion Matrix dengan Hidden Node 9 pada Data Scale 15 .....	112
Tabel 6.43 Confusion Matrix dengan Hidden Node 10 pada Data Scale 15.....	113
Tabel 6.44 Confusion Matrix dengan Hidden Node 11 pada Data Scale 15.....	113
Tabel 6.45 Hasil Uji Performa Klasifikasi ANN Scale 15 Epoch 3000 .....	114
Tabel 6.46 Confusion Matrix dengan Hidden Node 2 pada Data Scale 20 .....	115
Tabel 6.47 Confusion Matrix dengan Hidden Node 3 pada Data Scale 20 .....	115
Tabel 6.48 Confusion Matrix dengan Hidden Node 4 pada Data Scale 20 .....	116
Tabel 6.49 Confusion Matrix dengan Hidden Node 5 pada Data Scale 20 .....	116
Tabel 6.50 Confusion Matrix dengan Hidden Node 6 pada Data Scale 20 .....	117
Tabel 6.51 Confusion Matrix dengan Hidden Node 7 pada Data Scale 20 .....	117
Tabel 6.52 Confusion Matrix dengan Hidden Node 8 pada Data Scale 20 .....	118
Tabel 6.53 Confusion Matrix dengan Hidden Node 9 pada Data Scale 20 .....	118
Tabel 6.54 Confusion Matrix dengan Hidden Node 10 pada Data Scale 20.....	119

Tabel 6.55 Confusion Matrix dengan Hidden Node 11 pada Data Scale 20 .....	119
Tabel 6.56 Hasil Uji Performa Klasifikasi ANN Scale 20 Epoch 3000 .....	120
Tabel 6.57 Confusion Matrix dengan Hidden Node 2 pada Data Scale 25.....	121
Tabel 6.58 Confusion Matrix dengan Hidden Node 3 pada Data Scale 25.....	121
Tabel 6.59 Confusion Matrix dengan Hidden Node 4 pada Data Scale 25.....	122
Tabel 6.60 Confusion Matrix dengan Hidden Node 5 pada Data Scale 25.....	122
Tabel 6.61 Confusion Matrix dengan Hidden Node 6 pada Data Scale 25.....	123
Tabel 6.62 Confusion Matrix dengan Hidden Node 7 pada Data Scale 25.....	123
Tabel 6.63 Confusion Matrix dengan Hidden Node 8 pada Data Scale 25.....	124
Tabel 6.64 Confusion Matrix dengan Hidden Node 9 pada Data Scale 25.....	124
Tabel 6.65 Confusion Matrix dengan Hidden Node 2 pada Data Scale 25.....	125
Tabel 6.66 Confusion Matrix dengan Hidden Node 11 pada Data Scale 25 .....	125
Tabel 6.67 Hasil Uji Performa Klasifikasi ANN Scale 25 Epoch 3000 .....	126
Tabel 6.68 Confusion Matrix dengan Hidden Node 2 pada Data Scale 30.....	127

Tabel 6.69 Confusion Matrix dengan Hidden Node 3 pada Data Scale 30.....	127
Tabel 6.70 Confusion Matrix dengan Hidden Node 4 pada Data Scale 30.....	128
Tabel 6.71 Confusion Matrix dengan Hidden Node 5 pada Data Scale 30.....	128
Tabel 6.72 Confusion Matrix dengan Hidden Node 6 pada Data Scale 30.....	129
Tabel 6.73 Confusion Matrix dengan Hidden Node 7 pada Data Scale 30.....	129
Tabel 6.74 Confusion Matrix dengan Hidden Node 8 pada Data Scale 30.....	130
Tabel 6.75 Confusion Matrix dengan Hidden Node 9 pada Data Scale 30.....	130
Tabel 6.76 Confusion Matrix dengan Hidden Node 10 pada Data Scale 30.....	131
Tabel 6.77 Confusion Matrix dengan Hidden Node 11 pada Data Scale 30.....	131
Tabel 6.78 Hasil Uji Performa Klasifikasi ANN Scale 30 Epoch 3000 .....	132
Tabel 6.79 Model Terbaik setiap Scale .....	133
Tabel 6.80 Rancangan Parameter Uji Klasifikasi Lanjutan .	133
Tabel 6.81 Model Terbaik Uji Coba Lanjutan Klasifikasi ANN .....	134

## DAFTAR KODE PROGRAM

Kode Program 5.1 Cek Data < 900 .....	48
Kode Program 5.2 Menghitung Integrasi Time Series.....	49
Kode Program 5.3 Plot RR interval dan Random Walk .....	49
Kode Program 5.4 Pencarian Nilai Scales .....	50
Kode Program 5.5 Membagi Segmen Data .....	51
Kode Program 5.6 Menghitung Nilai Skewness dan Kurtosis .....	51
Kode Program 5.7 Perhitungan Fungsi Fluktuasi .....	52
Kode Program 5.8 Plot Fungsi Fluktuasi.....	53
Kode Program 5.9 Perhitungan Local Scaling Exponent.....	53
Kode Program 5.10 Plot Local Scaling Exponent .....	54
Kode Program 5.11 Perhitungan Parameter Rata-Rata Fungsi Fluktuasi berdasarkan Skewness .....	54
Kode Program 5.12 Perhitungan Parameter Rata-Rata Fungsi Fluktuasi berdasarkan Kurtosis .....	55
Kode Program 5.13 Perhitungan Parameter Rata-Rata Local Scaling Exponent berdasarkan Skewness .....	56
Kode Program 5.14 Perhitungan Parameter Rata-Rata Local Scaling Exponent berdasarkan Kurtosis .....	57
Kode Program 5.15 Uji Signifikansi Wilcoxon Rank Sum Test .....	58

*(Halaman ini sengaja dikosongkan)*

# BAB I

## PENDAHULUAN

Pada bab pendahuluan ini dijelaskan mengenai latar belakang masalah, perumusan masalah, Batasan masalah, tujuan dan manfaat tugas akhir, serta relevansi penelitian tugas akhir dengan bidang minat yang terdapat pada Departemen Sistem Informasi ITS.

### 1.1. Latar Belakang Masalah

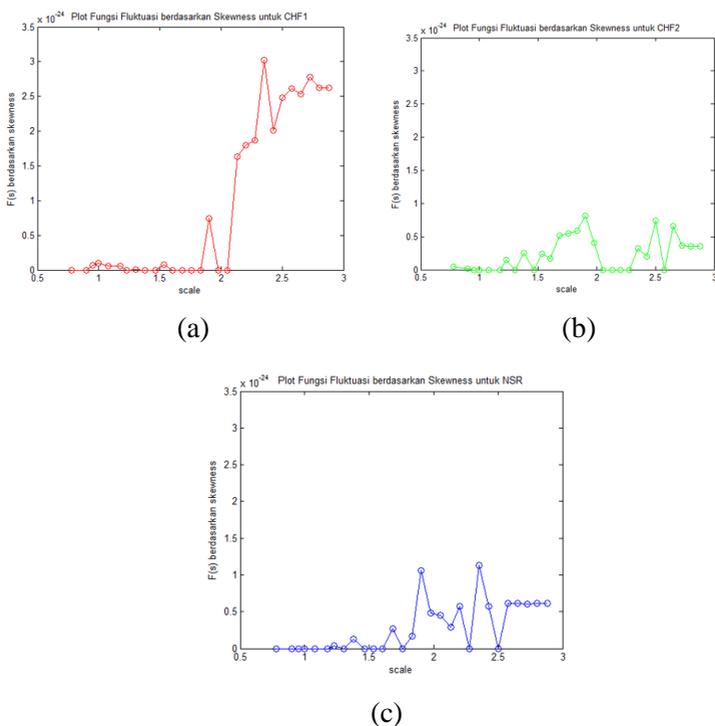
*Intensive Care Unit (ICU)* merupakan salah satu bagian penting di rumah sakit. Ketika pasien memasuki ruang ICU, kondisi dan prognosis pasien akan dilakukan pengecekan secara intensif. Prognosis merupakan prediksi dari kemungkinan hasil akhir dari suatu penyakit, apakah kondisi seorang pasien yang menderita penyakit tersebut dapat pulih atau tidak. Prognosis dilakukan untuk menentukan perawatan terbaik bagi seorang pasien, sehingga ICU dapat memberikan pelayanan yang lebih baik. Dalam menentukan prognosis seorang pasien, saat ini ahli medis sebagian besar menggunakan bantuan sistem *scoring* yang sudah banyak berkembang. Beberapa jenis sistem *scoring* yang ada saat ini antara lain, *Acute Physiology Chronic Health Evaluation (APACHE) I-IV*, *The Simplified Acute Physiology Score (SAPS)*, *Mortality Probability Model (MPM)* [1]. Dalam melakukan prognosis menggunakan sistem tersebut, dibutuhkan banyak parameter penilaian yang membutuhkan waktu lama untuk mendapatkannya. Beberapa parameter yang digunakan antara lain umur, jenis kelamin, tekanan darah, kandungan limfosit, kandungan haemoglobin dan kandungan asam urat. Padahal prognosis dapat dilakukan dengan memanfaatkan sinyal elektrokardiogram (EKG) pasien yang direkam secara terus menerus pada *bedside monitor* ICU, sehingga data dapat diperoleh dengan lebih cepat, dan bersifat *real time* [2].

Sinyal EKG merupakan rekam gelombang aktivitas kelistrikan otot jantung yang direkam melalui alat elektrokardiograf [3]. EKG terdiri dari 5 bentuk gelombang, yaitu yang memiliki label P, Q, R, S, dan T. Setiap kondisi gelombang penyusun sinyal EKG tersebut memiliki arti tersendiri dan dapat menunjukkan kondisi jantung pasien saat itu [4]. Dengan melakukan analisis short-term dan long-term pada sinyal EKG, hasil tersebut dapat digunakan untuk menentukan variasi dari detak jantung yang biasa disebut dengan *Heart Rate Variability* (HRV). Sinyal HRV didapatkan dari hasil perhitungan R-R interval sinyal EKG. Dengan mengetahui sinyal HRV seseorang, kita dapat mengetahui keseimbangan saraf otonom dalam mengatur keseimbangan saraf simpatis dan parasimpatis orang tersebut. Sehingga *HRV* dapat digunakan sebagai indikator gangguan pada sistem saraf otonom [5]. Oleh karena itu, saat ini mulai banyak penelitian yang memanfaatkan sinyal HRV dalam menentukan hasil prognosis pasien [2].

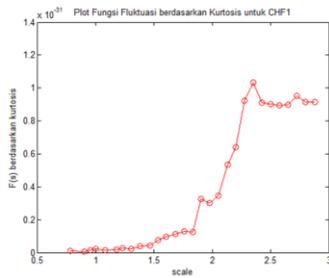
Sinyal HRV memiliki beberapa karakteristik seperti tipe data time series, struktur data nonlinear dan pola data nonstasioner, memiliki sifat invariant, dan volatility yang tinggi [5], [6]. Untuk melakukan analisis pada skala volatility sinyal HRV dapat dilakukan dengan melakukan perhitungan pada nilai *skewness* dan *kurtosis*. *Skewness* menunjukkan nilai asimetri distribusi probabilitas dari variabel acak bernilai riil. Sedangkan *kurtosis* menunjukkan nilai perubahan dari tailedness [7].

Pada penelitian sebelumnya dalam melakukan deteksi penyakit jantung kongestif dengan melakukan ekstraksi sinyal HRV, plot nilai *skewness* dan *kurtosis* memiliki hubungan dan perbedaan plot nilai pada beberapa level gagal jantung pasien dan pasien normal. Pada penelitian tersebut, pasien dibedakan menjadi pasien gagal jantung level 3-4 (chf1), level 1-3 (chf2), dan pasien normal. Perbedaan plot nilai *skewness* dan *kurtosis* antar level pasien gagal jantung dan pasien yang normal dapat dilihat pada Gambar 1.1 dan Gambar 1.2. Perbedaan plot nilai tersebut

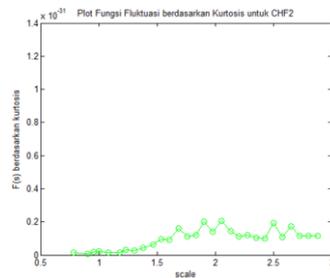
menunjukkan bahwa nilai *skewness* dan *kurtosis* memiliki hubungan dengan sinyal HRV, sehingga dapat digunakan untuk membedakan kondisi seorang pasien. Untuk melakukan ekstraksi sinyal HRV pada penelitian tersebut digunakan metode *Higher-Order Moments Detrended Fluctuation Analysis* (HOMDFA) dimana merupakan perkembangan dari metode *Detrended Fluctuation Analysis*.



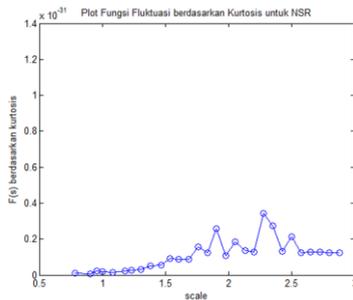
**Gambar 1.1** Plot Fungsi Fluktuasi Skewness untuk (a) CHF1, (b) CHF2, (c) Normal



(a)



(b)



(c)

**Gambar 1.2** Plot Fungsi Fluktuasi Kurtosis untuk (a) CHF1, (b)CHF2, (c)Normal

Metode HOMDFA cocok digunakan untuk data yang memiliki karakteristik non stasioner dan memiliki volatility dengan melakukan perhitungan pada nilai *skewness* dan *kurtosis*, dimana perhitungan nilai tersebut tidak dilakukan apabila menggunakan metode DFA. Padahal dapat dilihat pada penelitian sebelumnya jika nilai tersebut memiliki perbedaan dan hubungan dengan sinyal HRV untuk membedakan kondisi seorang pasien [8]. Oleh karena itu pada penelitian ini digunakan metode HOMDFA dalam melakukan ekstraksi sinyal HRV.

Setelah dilakukan pengolahan data HRV menggunakan HOMDFA, akan dihasilkan beberapa fitur dari sinyal HRV. Hasil dari ekstraksi fitur tersebut yang telah lolos uji signifikansi akan dijadikan input untuk melakukan klasifikasi dengan menggunakan metode *Artificial Neural Network* (ANN). ANN akan melakukan klasifikasi sehingga dapat dihasilkan klasifikasi prognosis pasien [9]. ANN cocok digunakan untuk melakukan analisis data kompleks yang bersifat nonstasioner. ANN juga memiliki kemampuan mempelajari data dan dapat melakukan eksekusi model dengan cepat [10]. ANN juga merupakan metode yang sudah sering digunakan dalam melakukan klasifikasi data medis, dimana hasil klasifikasi menggunakan ANN juga cenderung baik [8]. Oleh karena itu, ANN dianggap cocok untuk digunakan dalam melakukan klasifikasi hasil prognosis pasien.

Dalam tugas akhir ini akan membahas mengenai klasifikasi prognosis pasien dengan menggunakan metode *Artificial Neural Network* berdasarkan hasil ekstraksi data menggunakan *Higher-Order Moments Detrended Fluctuation Analysis* pada sinyal HRV. Hasil akhir dari tugas akhir ini berupa hasil klasifikasi dan akurasi prognosis pasien ICU. Sehingga diharapkan dengan adanya penelitian ini dapat membantu ahli medis dalam menentukan tingkat prognosis pasien dengan lebih cepat karena menggunakan data *real-time* dari sinyal EKG yang didapatkan dari *bedside monitor ICU*.

## **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 prognosis dengan *Artificial Neural Network* menggunakan fitur *Higher-Order Moments Detrended Fluctuation Analysis*?

3. Bagaimana hasil klasifikasi dan akurasi prognosis menggunakan *Artificial Neural Network*?

### 1.3. Batasan Masalah

Batasan masalah dalam pengerjaan tugas akhir ini adalah

1. Data yang digunakan pada penelitian ini adalah data sinyal EKG pasien ICU yang didapatkan dari PhysioNet.
2. Data EKG yang digunakan adalah data *bedside monitoring* pasien ICU dewasa dengan diagnosis *sepsis*.
3. Struktur ANN yang digunakan merupakan *Backpropagation*.
4. Model ekstraksi data dibuat menggunakan Bahasa pemrograman python.
5. Klasifikasi ANN dilakukan dengan menggunakan *tools* WEKA.

### 1.4. Tujuan Tugas Akhir

Tujuan dari tugas akhir ini adalah

1. Untuk mengetahui hasil ekstraksi fitur *Higher-Order Moments Detrended Fluctuation Analysis* pada sinyal HRV denyut jantung
2. Untuk mengetahui model klasifikasi prognosis dengan *Artificial Neural Network* menggunakan fitur *Higher-Order Moments Detrended Fluctuation Analysis*
3. Untuk mengetahui hasil klasifikasi dan akurasi prognosis pasien ICU dengan menggunakan *Artificial Neural Network* pada sinyal HRV denyut jantung yang telah dilakukan ekstraksi dengan *Higher-Order Moments Detrended Fluctuation Analysis*.

## 1.5. Manfaat Tugas Akhir

Manfaat yang diberikan dengan adanya tugas akhir ini adalah membantu instansi kesehatan dalam melakukan estimasi prognosis pasien ICU, sehingga dapat menentukan penanganan yang tepat bagi pasien tersebut. Selain itu, dengan adanya penelitian ini juga menambah referensi dalam penggunaan metode ekstraksi *Higher-Order Moments Detrended Fluctuation Analysis* dan juga penggunaan *Artificial Neural Network* dalam menentukan estimasi prognosis pasien ICU.

## 1.6. Relevansi

ICU yang menjadi salah satu bagian penting rumah sakit, dalam melakukan perawatan pasiennya akan melakukan prognosis untuk menentukan jenis perawatan yang tepat bagi pasiennya. Prognosis yang saat ini banyak digunakan di bagian ICU masih menggunakan sistem scoring yang cenderung kurang efektif. Agar dapat melakukan prognosis dengan lebih efektif, dapat dilakukan penentuan prognosis dengan memanfaatkan sinyal HRV yang didapatkan dari perhitungan nilai R-R interval sinyal elektrokardiogram yang direkam secara terus menerus di *bedside monitor* ICU. Oleh karena itu, penelitian perlu dilakukan dengan harapan dapat membantu ahli medis agar dapat melakukan prognosis dengan lebih efektif dan pelayanan ICU dapat meningkat.

Metode ekstraksi yang digunakan dalam penelitian ini yaitu *Higher-Order Moments Detrended Fluctuation Analysis* merupakan metode yang masih baru, yang berasal dari perkembangan metode *DFA*. Hingga saat ini masih sedikit penelitian terkait metode tersebut. Terutama penelitian yang memanfaatkan metode tersebut untuk melakukan ekstraksi sinyal HRV dalam menentukan prognosis pasien. Sehingga metode tersebut memiliki potensi besar untuk diteliti lebih lanjut pada sinyal biomedis atau penyakit lainnya.

Penyusunan tugas akhir bertujuan memenuhi syarat kelulusan tahap sarjana serta sebagai bentuk implementasi disiplin ilmu yang telah didapatkan selama pendidikan perkuliahan di Jurusan Sistem Informasi ITS. Topik yang diangkat dalam penelitian tugas akhir adalah klasifikasi prognosis ini berkaitan dengan mata kuliah yang telah dipelajari sebelumnya yaitu Sistem Cerdas, Sistem Pendukung Keputusan, dan Statistika.

## BAB II TINJAUAN PUSTAKA

Pada bab ini menjelaskan tentang tinjauan pustaka yang digunakan sebagai acuan dan landasan teori dalam pengerjaan tugas akhir. Tinjauan pustaka yang dijelaskan mencakup studi sebelumnya dan dasar teori.

### 2.1. Penelitian Sebelumnya

Beberapa penelitian sebelumnya yang dijadikan acuan dalam pengerjaan tugas akhir disajikan dalam Tabel 2.1.

**Tabel 2.1 Penelitian Sebelumnya**

<b>Penelitian 1</b>	
Judul Paper	<i>Prediction of Mortality in Patients with Sepsis Using Detrended Fluctuation Analysis (DFA) of Heart Rate Variability</i> [11]
Penulis; Tahun	Peyman Ghasemi dan Mohammad Reza Raoufy; 2016
Deskripsi Umum Penelitian	Pada penelitian ini digunakan metode <i>Detrended Fluctuation Analysis (DFA)</i> dalam melakukan analisis pada <i>Heart Rate Variability (HRV)</i> yang kemudian akan digunakan untuk melakukan prognosis berupa prediksi kematian dalam jangka waktu 9 jam sebelum kematian pasien. Data yang digunakan merupakan database <i>Multiparameter Intelligent Monitoring in Intensive Care II (MIMIC-II)</i> yang didapatkan dari PhysioNet. Database tersebut berisi 25.328 data pasien dewasa yang dirawat di ICU selama periode 2001-2007. Data MIMIC-II terdiri dari rincian data klinis hingga

	gelombang elektrokardiogram masing-masing pasien. Hasil dari penelitian ini menunjukkan bahwa analisis HRV dengan DFA dapat memprediksi kematian 9 jam sebelum kematian.
Keterkaitan Penelitian	Penggunaan metode <i>Detrended Fluctuation Analysis</i> pada <i>Heart Rate Variability</i> yang digunakan dalam melakukan prognosis pada pasien ICU dapat menjadi referensi untuk metodologi yang akan digunakan dalam penelitian ini. Dikarenakan metode <i>Higher-Order Moments Detrended Fluctuation Analysis</i> yang digunakan dalam penelitian ini merupakan perkembangan dari metode DFA.
<b>Penelitian 2</b>	
Judul Paper	Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis pada Variabilitas Denyut Jantung [8]
Penulis; Tahun	Nurfiana Dwi Astuti; 2017
Deskripsi Umum Penelitian	Pada penelitian ini dilakukan penggunaan metode ekstraksi fitur <i>Higher-Order Moments Detrended Fluctuation Analysis</i> pada sinyal <i>Heart Rate Variability</i> (HRV) untuk klasifikasi penyakit gagal jantung kongestif menggunakan metode <i>Artificial Neural network (ANN)</i> . Penelitian ini dilakukan pada data 72 pasien normal dan 44 pasien penyakit gagal jantung kongestif yang diambil dari PhysioNet. Hasil dari penelitian ini adalah klasifikasi pasien dengan kondisi penyakit gagal jantung dan pasien normal.

Keterkaitan Penelitian	Penerapakan ekstraksi fitur <i>Higher-Order Moments Detrended Fluctuation Analysis</i> pada sinyal HRV dan penggunaan metode klasifikasi <i>Artificial Neural network (ANN)</i> dapat menjadi referensi untuk metodologi yang akan digunakan pada tugas akhir ini.
<b>Penelitian 3</b>	
Judul Paper	Detrended Fluctuation Analysis based on Higher-Order Moments of Financial Time Series [7]
Penulis; Tahun	Teng, Yue Shang, Pengjian; 2017
Deskripsi Umum Penelitian	Pada penelitian ini digunakan metode <i>Higher-Order Detrended Fluctuation Analysis</i> dengan menambahkan penilaian <i>skewness</i> dan <i>kurtosis</i> pada penerapan metode <i>Detrended Fluctuation Analysis (DFA)</i> . Penilaian <i>skewness</i> dan <i>kurtosis</i> digunakan 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.
Keterkaitan Penelitian	Penerapan metode <i>Higher-Order Moments Detrended Fluctuation Analysis</i> dapat menjadi referensi untuk metodologi yang akan digunakan pada tugas akhir.

## **2.2. Dasar Teori**

Pada sub bab ini akan dijelaskan konsep-konsep teori yang dibahas dalam penelitian tugas akhir ini.

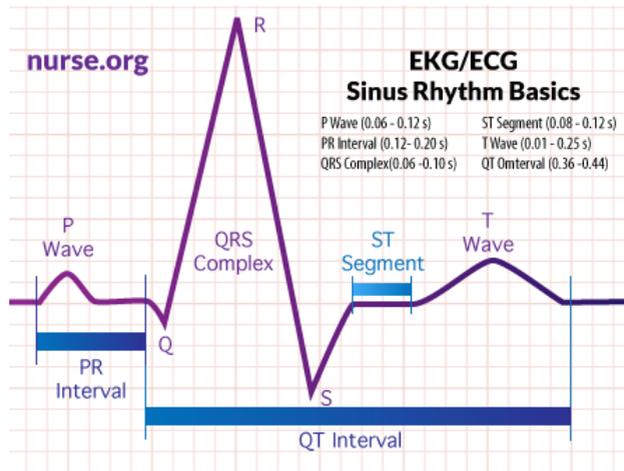
### **2.2.1. Prognosis**

Prognosis pada dunia medis merupakan prediksi dari kemungkinan hasil akhir dari suatu penyakit sehingga dapat mengetahui tindakan perawatan apa yang perlu dilakukan. Dalam melakukan prognosis, didasarkan pada pengetahuan umum tentang *pathogenesis* dan juga faktor risiko seorang individu dapat menderita suatu penyakit. Prognosis merupakan hal yang krusial dalam menentukan perawatan yang tepat terhadap pasien untuk dilakukan kedepannya. Dalam melakukan prognosis, biasanya seorang ahli medis menggunakan bantuan sistem scoring. Beberapa model penilaian yang berkembang adalah *Acute Physiology Chronic Health Evaluation* (APACHE) I-IV, *The Simplified Acute Physiology Score* (SAPS), *Mortality Probability Model* (MPM) dan *Trauma Injury Severity Scores* (TRISS) [1]. Penentuan skala penilaian dalam model penelitian tersebut ditafsirkan berdasarkan tanda fisiologis melalui proses manual dan intermitten [2].

### **2.2.2. Elektrokardiogram**

Elektrokardiogram (EKG) merupakan sinyal yang menggambarkan informasi kondisi aktivitas listrik dari otot jantung yang diambil dengan menggunakan alat bernama elektrokardiograf [3]. EKG merupakan salah satu alat penting yang banyak digunakan pada dunia medis untuk melakukan diagnosa, maupun menentukan potensi terjadinya ancaman suatu penyakit. Sinyal EKG dapat digunakan untuk menentukan variasi dari detak jantung [11]. EKG terdiri dari 5 bentuk gelombang, yaitu yang memiliki label P, Q, R, S, dan T [4].

Contoh gelombang EKG pada kondisi normal dapat dilihat pada Tabel 2.1 [12].



**Gambar 2.1** Sinyal Elektrokardiogram

Penjelasan untuk masing-masing komponen gelombang pada EKG dapat dilihat pada Tabel 2.2[4] :

**Tabel 2.2** Komponen EKG

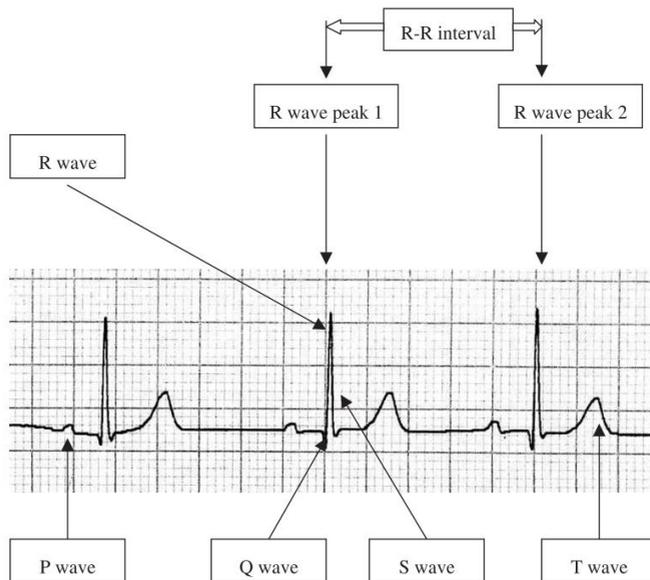
Komponen EKG	Deskripsi
Gelombang P	Merupakan komponen pertama pada gelombang EKG normal, yang terletak sebelum kompleks QRS, dan memiliki defleksi positif.
Interval PR	Jarak antara awal gelombang P dengan awal kompleks QRS
Kompleks QRS	Kompleks QRS terdiri dari gelombang Q, R, dan S. Kompleks QRS menggambarkan seluruh fase depolarisasi ventrikel.

Komponen EKG	Deskripsi
Gelombang Q	Merupakan defleksi negative pertama yang terjadi pada kompleks QRS, dimana menggambarkan awal depolarisasi ventrikel.
Gelombang R	Merupakan defleksi positif pertama pada kompleks QRS, dimana menggambarkan fase depolarisasi ventrikel kiri.
Gelombang S	Merupakan defleksi negative yang terjadi setelah gelombang R, dimana menggambarkan fase depolarisasi ventrikel kanan.
Gelombang T	Menggambarkan proses repolarisasi ventrikel.
Interval PR	Jarak antara awal gelombang P dengan awal kompleks QRS
Interval QT	Pengukuran waktu dari awal QRS sampai akhir gelombang T yang merepresentasikan aktivitas ventrikel
Segemen ST	Merepresentasikan akhir dari konduksi ventrikel dan merupakan awal dari proses repolarisasi ventrikel.

### 2.2.3. Heart Rate Variability

*Heart Rate Variability* (HRV) merupakan fenomena fisiologis berupa variasi interval waktu antar *heart rate* (HR). Sinyal HRV merupakan tipe data time series, struktur data nonlinear, dan pola data nonstasioner. Sinyal HRV didapatkan dari perhitungan waktu interval dalam *milliseconds* (ms) antar gelombang R (R-R interval) pada sinyal EKG [13]. Contoh ilustrasi gambar R-R interval dapat dilihat pada Gambar 2.2. HRV mencerminkan keseimbangan sistem saraf otonom yang mengatur keseimbangan antara saraf simpatis dan parasimpatis. Sehingga HRV dapat digunakan sebagai indikator gangguan

pada sistem saraf otonom. Selain itu, saat ini HRV juga telah dianggap sebagai parameter interaksi antara sistem otak dan kardiovaskular [5]. Oleh karena itu, saat ini mulai banyak penelitian yang memanfaatkan sinyal HRV dalam menentukan hasil prognosis pasien. Berdasarkan penelitian yang telah dilakukan, semakin kecilnya nilai HRV, berbanding lurus dengan semakin tingginya tingkat *morbidity* dan *mortality* [2].



**Gambar 2.2 R-R Interval pada Sinyal EKG**

#### **2.2.4. Artificial Neural Network**

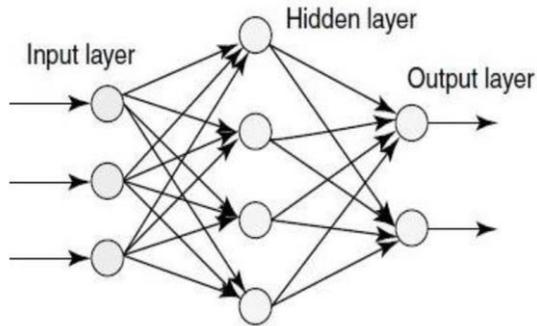
*Artificial Neural Network (ANN)* merupakan sebuah model komputasi yang terinspirasi dari sistem saraf pusat manusia yang terdiri dari neuron yang saling berhubungan. Seperti halnya dengan kemampuan sistem saraf manusia yang mampu belajar dan mengenal pola, *ANN* juga mampu melakukan hal tersebut sehingga dapat melakukan perhitungan terhadap input

yang diberikan. Dengan kemampuan tersebut, saat ini *ANN* banyak digunakan untuk menyelesaikan permasalahan kompleks di berbagai bidang. [14].

*Neural Network* sederhana terdiri dari tiga *layer* (lapisan) jaringan, antara lain [15], [16]:

1. *Input Layer* (Lapisan masukan)  
Merupakan lapisan yang menerima informasi untuk diteruskan pada *hidden layer*, yang akan diproses lebih lanjut. Jumlah dari *input layer* bervariasi, disesuaikan jumlah *input* yang dibutuhkan.
2. *Hidden Layer* (Lapisan Tersembunyi)  
*Hidden layer* merupakan lapisan yang berada diantara *input* dan *output layer*. *Hidden layer* akan menerima masukan informasi dari *input layer*, kemudian meneruskannya pada *output layer*. Jumlah dari *hidden layer* bervariasi, bergantung pada sifat, kekompleksan masalah, serta berdasarkan hasil percobaan yang dilakukan dalam arsitektur yang terbaik.
3. *Output Layer* (Lapisan Keluaran)  
*Output layer* menerima hasil pemrosesan informasi dari *hidden layer* dan memberikan hasil tersebut pada *external user*. Jumlah *output layer* bervariasi, disesuaikan dengan jumlah *output* yang diinginkan.

Visualisasi gambar *ANN* yang terdiri dari *input layer*, *hidden layer*, dan *output layer*, dapat dilihat pada Gambar 2.3[14].



**Gambar 2.3 Multilayer ANN**

Dalam membangun model *ANN*, terdapat tiga tahapan umum yang dilakukan, antara lain [14]:

1. *Data Collection* (Mengumpulkan data)  
Merupakan proses pemilihan variable input dan output yang sesuai dengan parameter yang ditentukan.
2. *Data Division* (Pembagian data)  
Merupakan tahapan pemeriksaan normalitas data, dan menghilangkan data yang tidak sesuai.
3. *Reduction to Practice*  
Merupakan proses pemilihan struktur *ANN* dan algoritma yang sesuai untuk sampel data sehingga model *ANN* yang akan digunakan dalam menyelesaikan permasalahan dapat terbentuk.

Beberapa kelebihan dari *ANN*, antara lain [15] :

1. Memiliki kemampuan adaptif untuk mempelajari suatu hal
2. Bersifat universal karena dapat diterapkan pada semua jenis data
3. Dapat melakukan operasi perhitungan secara *real time*
4. Dapat mengenali suatu pola data

5. Dapat memodelkan sistem secara non-linear dengan baik
6. Fleksibel terhadap lingkungan yang bersifat dinamis / terjadi perubahan informasi secara terus menerus
7. Mampu menangani permasalahan yang kompleks untuk diselesaikan dengan pendekatan tradisional seperti statistik inferensial

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

*Higher-Order Moments Detrended Fluctuation Analysis* (HOMDFA) merupakan metode hasil perkembangan dari metode *Detrended Fluctuation Analysis* (DFA). Dimana pada metode HOMDFA memperhitungkan nilai *skewness* dan *kurtosis* untuk mengetahui *volatility scalling property* pada sistem dinamik yang kompleks [7]. Metode DFA dapat digunakan untuk melakukan analisis data *time series* non-linear dan non-stasioner yang kompleks, seperti sinyal EKG. Sehingga, metode HOMDFA yang merupakan perkembangan metode DFA juga dapat digunakan untuk melakukan analisis pada data bertipe tersebut [11]. Berikut merupakan tahapan dalam menggunakan metode HOMDFA [7] :

**Langkah 1:** Menghitung rata-rata

Anggap  $x(i)$  untuk  $i=1 \dots N$  dengan rumus

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

Dimana :

$x$  = nilai dari setiap data

$N$  = panjang data

$i$  = index data

**Langkah 2:** Mengitung integrasi time series

$$y(i) = \sum_{k=1}^i [x_k - x_{ave}], \quad i = 1, \dots, N \quad (2)$$

**Langkah 3:** Membagi time series yang terintegrasi pada 99 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

$$\langle X_s(i) \rangle = \frac{1}{s} \sum_{i=1}^s X_s[(v-1)s + i], \quad v = 1, 2, \dots, N_s, \quad (5)$$

$$\begin{aligned} \langle X_s(i) \rangle &= \frac{1}{s} \sum_{i=1}^s X_s[N - (v - N_s)s + i], \quad v \\ &= N_s + 1, N_s + 2, \dots, 2N_s, \end{aligned} \quad (6)$$

$$\sigma^2(X_s(i)) = \langle X_s^2(i) \rangle - \langle X_s(i) \rangle^2, \quad (7)$$

Dimana :

$s = scale$

$v = \text{segmen}$

$\sigma = variance$

**Langkah 4:** Menghitung fungsi fluktuasi

Fungsi fluktuasi  $q$ th order didapatkan setelah merata-ratakan  $2N_s$  segment.

$$F(s) = \left( \frac{1}{2N_s} \sum_{v=1}^{2N_s} [F^2(s, v)] \right)^{\frac{1}{2}} \quad (8)$$

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

$$F(s) \sim s^\alpha \quad (9)$$

Dimana  $\alpha$  adalah *scaling exponent* yang merepresentasikan sifat korelasi dari sinyal. Yang menjadi fokus dan alat kuantitatif utama pada metode ini merupakan variasi dari nilai *local scaling exponent* dari time series [7]. Untuk menentukan *scaling behavior* dari fungsi fluktuasi, dibutuhkan analisis nilai *local scaling exponent* yang dapat dihitung dengan rumus:

$$\alpha(s_k) = \frac{\log[F(s_{k+1})] - \log[F(s_{k-1})]}{\log[s_{k+1}] - \log[s_{k-1}]} \quad (10)$$

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

**2.2.6. Uji Rank Sum Wilcoxon**

Uji *Wilcoxon Rank-Sum (WRS)* merupakan salah satu uji statistik nonparametrik dimana tidak adanya persyaratan pada persebaran data yang akan diuji harus berdistribusi normal. Uji statistik nonparametrik dapat digunakan untuk melakukan analisis data jenis nominal atau ordinal yang pada umumnya tidak memiliki distribusi normal. Uji WRS dilakukan dengan menggabungkan kemudian mengurutkan nilai data dari kedua sampel. Data dikatakan lolos uji WRS apabila nilai *p-value*  $<$

0.05, dimana berarti adanya perbedaan distribusi antara kedua sampel data [17].

### 2.2.7. Uji Performa

Uji performa yang dapat digunakan untuk mengetahui performa hasil klasifikasi ANN adalah *Confusion Matrix* dan *Receiver Operating Characteristic* (ROC). Dengan melakukan perhitungan *Confusion Matrix*, dapat diketahui rincian dari kesalahan klasifikasi. Bentuk tabel *confusion matrix* untuk dua class dapat dilihat pada Tabel 2.3.

**Tabel 2.3** Tabel Confussion Matrix

		<i>Actual Class</i>	
		<i>Class 1</i>	<i>Class 2</i>
<i>Predicted Class</i>	<i>Class 1</i>	<i>True positive</i>	<i>False negative</i>
	<i>Class 2</i>	<i>False positive</i>	<i>True negative</i>

Dari tabel tersebut, dapat diketahui *accuracy*, *sensitivity*, dan *specificity* dari hasil klasifikasi. *Accuracy* digunakan untuk mengetahui persentase ketepatan prediksi model ANN, *sensitivity* digunakan untuk mengukur persentase ‘*true positive*’ yang dapat diidentifikasi dengan benar, sedangkan *specificity* digunakan untuk mengukur persentase ‘*true negative*’ yang dapat diidentifikasi dengan benar. Rumus perhitungan *accuracy*, *sensitivity*, dan *specificity* adalah sebagai berikut:

Accuracy (%)

$$= \frac{\text{jumlah positif benar} + \text{jumlah negatif benar}}{\text{jumlah total data}} \times 100\% \quad (11)$$

Sensitivity

$$= \frac{\text{jumlah positif benar}}{\text{jumlah positif benar} + \text{jumlah negatif salah}} \quad (12)$$

Specificity

$$= \frac{\text{jumlah negatif benar}}{\text{jumlah negatif benar} + \text{jumlah positif salah}} \quad (13)$$

Setelah melakukan perhitungan *accuracy*, *sensitivity*, dan *specificity*, dilakukan perhitungan ROC untuk melakukan analisis secara visual hasil prediksi *ANN* dengan memilih *classifier* berdasarkan performanya. Visualisasi hasil perhitungan ROC biasanya digambarkan dengan *Area Under ROC Curve* (AUC). Nilai AUC didapatkan dengan menggunakan perhitungan rumus:

$$AUC = \frac{1}{2} \sum_{i=1}^n (x_{i+1} - x_1)(y_{i+1} - y_i) \quad (14)$$

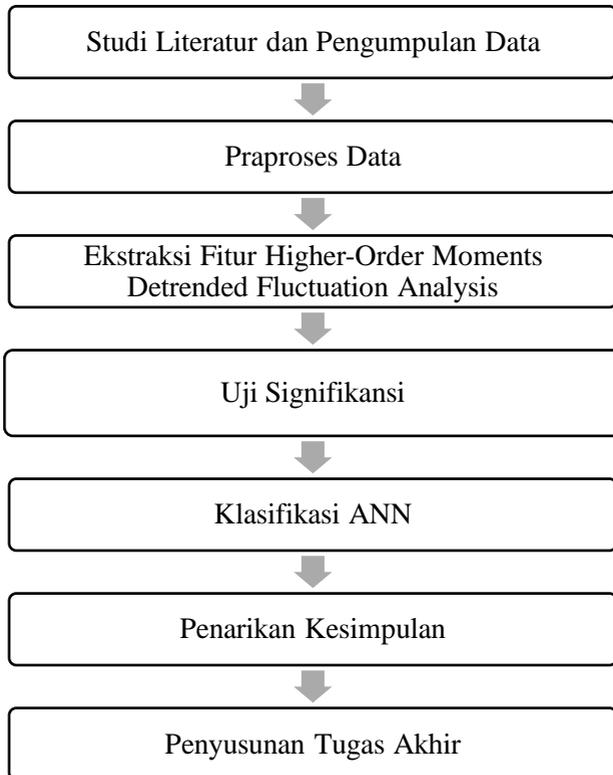
Apabila nilai AUC yang dihasilkan dari perhitungan semakin mendekati 1, maka hasil klasifikasi semakin baik. Sedangkan apabila semakin mendekati 0, maka hasil klasifikasi semakin buruk [18].

## **BAB III METODOLOGI**

Pada bab ini akan diberikan gambaran berupa diagram serta penjelasan mengenai metodologi yang akan menjadi panduan untuk menyelesaikan penelitian tugas akhir.

### **3.1. Diagram Metodologi**

Pada sub bab ini diberikan gambaran umum metodologi yang Gambar 3.1.



**Gambar 3.1 Diagram Metodologi**

Pada sub bab ini akan dijelaskan mengenai metodologi dalam mengerjakan penelitian tugas akhir ini.

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

Pada tahapan ini akan dilakukan studi literatur dan pengumpulan data yang akan digunakan pada penelitian ini. Studi literatur dilakukan dengan mengumpulkan berbagai referensi seperti buku pustaka, jurnal atau *paper* pada penelitian sebelumnya, ataupun dokumen lain yang sesuai dengan topik penelitian. Dengan studi literatur diharapkan peneliti dapat lebih memahami dasar-dasar teori yang mendukung atau berkaitan dengan permasalahan yang ingin diselesaikan. Oleh karena itu, pada tahapan ini peneliti melakukan studi literature terkait metode yang akan digunakan pada penelitian ini, yaitu HOMDFA dengan meninjau kembali penelitian-penelitian terdahulu untuk dijadikan acuan, serta melakukan proses pengambilan data yang dilakukan melalui website PhysioNet.

### **3.1.2. Praproses Data**

Pada tahapan ini akan dilakukan persiapan pengolahan data yang telah didapatkan dari PhysioNet sehingga dapat dilakukan proses ekstraksi fitur pada tahapan selanjutnya. Data yang diambil dari PhysioNet merupakan data pasien ICU yang didapatkan dari rekaman *bedside monitor* ICU.

#### **3.1.2.1. Pengelompokan Data**

Data EKG yang telah didapatkan dari PhysioNet akan dikelompokkan berdasarkan label data yaitu prognosis baik dan buruk. Sehingga dapat mempermudah proses pengolahan serta pengujian data yang akan dilakukan.

#### **3.1.2.2. Konversi Sinyal EKG menjadi HRV**

Masing-masing data EKG yang sudah dikelompokkan, akan dikonversikan menjadi sinyal HRV dengan cara menghitung R-R intervalnya, seperti yang telah dijelaskan pada sub bab 2.2.3.

Proses pengkonversian data dilakukan dengan menggunakan WFDB *package* pada *software* Cygwin.

### **3.1.2.3. Pemilihan Data**

Pada tahapan ini dilakukan pemilihan data yang sesuai untuk digunakan dalam penelitian. Data hasil konversi sinyal EKG menjadi HRV akan dilakukan pemotongan 10 data awal, dan data yang digunakan untuk analisis data pada tahapan selanjutnya merupakan 900 data awal setelah pemotongan data. Hal tersebut dikarenakan data awal biasanya merupakan data *noise*, sehingga data menjadi tidak akurat.

### **3.1.3. Ekstraksi Fitur Higher-Order Detrended Fluctuation Analysis**

Pada tahapan ini akan dilakukan ekstraksi fitur menggunakan HOMDFA. Input dari tahapan yaitu hasil konversi sinyal EKG menjadi HRV. Untuk melakukan ekstraksi fitur, terlebih dahulu akan dilakukan pembuatan kode program yang diterjemahkan dari rumusan matematis HOMDFA. Output dari tahapan ini adalah data hasil ekstraksi fitur.

### **3.1.4. Uji Signifikansi**

Pada tahapan ini dilakukan uji signifikansi data untuk menentukan fitur mana yang dapat digunakan untuk menjadi input pada tahapan klasifikasi ANN. Input dari tahapan ini adalah data hasil ekstraksi fitur. Output pada tahapan ini adalah data hasil ekstraksi fitur yang lolos uji signifikansi, sehingga dapat digunakan untuk input pada tahapan klasifikasi ANN

### **3.1.5. Klasifikasi ANN**

Pada tahapan ini akan dilakukan klasifikasi ANN yang terdiri dari pemodelan ANN, pelatihan model, pengujian model, serta uji performa. Input dari tahapan ini berupa data nilai ekstraksi fitur yang lolos uji signifikansi. Data tersebut akan dilakukan pembagian dengan perbandingan 70:30 untuk digunakan

sebagai data pelatihan dan pengujian. Output yang dihasilkan pada tahapan ini berupa hasil klasifikasi prognosis pasien.

#### **3.1.5.1. Pemodelan ANN**

Pada tahapan ini akan dilakukan pembuatan *classifier* / model ANN *backpropagation* berdasarkan arsitektur ANN yang terdiri dari *input layer*, *hidden layer*, dan *ouput layer*. *Input layer* berisikan nilai ekstraksi fitur yang lolos uji signifikansi. Penentuan jumlah node *hidden layer* dilakukan dengan menggunakan proses *trial and error*. Fungsi aktivasi yang akan digunakan adalah sigmoid biner, sedangkan jumlah untuk *output layer* adalah satu, yang berisikan hasil klasifikasi berupa prognosis baik atau buruk.

#### **3.1.5.2. Pelatihan Model**

Pada tahapan ini akan dilakukan pelatihan pada model ANN yang telah dibuat. Proses pelatihan dilakukan untuk melakukan pengenalan pola data terhadap model. Jumlah data yang digunakan dalam melakukan pelatihan adalah 70% dari total data yang signifikan dari hasil ekstraksi fitur *Higher Order Moments Detrended Fluctuation Analysis*.

#### **3.1.5.3. Pengujian Model**

Pada tahapan ini dilakukan pengujian model yang telah dibuat menggunakan data pengujian. Pengujian model dilakukan untuk menguji apakah model ANN yang telah dilakukan pelatihan dapat mengenali pola-pola data, selain data pelatihan. Jumlah data yang digunakan dalam melakukan pengujian adalah 30% dari total data yang signifikan dari hasil ekstraksi fitur *Higher Order Moments Detrended Fluctuation Analysis*.

#### **3.1.5.4. Uji Performa**

Pada tahapan ini akan dilakukan pengujian performa model ANN untuk tingkat akurasi hasil pemodelan. Pengujian performa dapat dilakukan dengan menggunakan *Confusion*

*Matrix* dan ROC. Pengujian performa dilakukan pada setiap model hasil percobaan untuk menentukan model mana yang memiliki performa terbaik, sehingga dapat digunakan untuk kedepannya.

### **3.1.6. Penarikan Kesimpulan**

Pada tahapan ini akan dilakukan penarikan kesimpulan dari hasil penerapan metode *Higher-Order Moments Detrended Fluctuation Analysis* untuk mengekstraksi fitur pada sinyal HRV dan hasil klasifikasi menggunakan ANN.

### **3.1.7. Penyusunan Tugas Akhir**

Pada tahapan terakhir ini dilakukan pembuatan buku laporan tugas akhir sebagai bentuk dokumentasi atas terlaksananya tugas akhir ini. Di dalam laporan tersebut mencakup :

#### **a. Bab I Pendahuluan**

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

#### **b. Bab II Tinjauan Pustaka**

Dalam bab ini 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**

Dalam bab ini akan dijelaskan mengenai tahapan apa saja yang dilakukan dalam pengerjaan penelitian tugas akhir ini.

#### **d. Bab IV Perancangan**

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

e. Bab V Implementasi

Dalam bab ini akan berisi tentang proses pengerjaan penelitian dan pembuatan model yang akan dilakukan untuk klasifikasi.

f. Bab VI Hasil dan Pembahasan

Dalam bab ini berisi tentang pembahasan dalam penyelesaian permasalahan yang dibahas pada pengerjaan tugas akhir ini.

g. Bab VII Kesimpulan dan Saran

Dalam bab ini berisi tentang kesimpulan serta saran yang ditujukan untuk kelengkapan penyempurnaan tugas akhir ini

## **BAB IV PERANCANGAN**

Pada bab ini berisikan penjelasan persiapan perancangan dari penelitian tugas akhir yang meliputi pengambilan serta pengolahan data, serta bagaimana proses penelitian tugas akhir akan dilakukan.

### **4.1. Pengumpulan Data**

Pada bagian ini akan dilakukan pengumpulan data yang didapatkan dari website [physionet.org](http://physionet.org), berupa data sinyal EKG dari *bedside monitor* ICU serta data informasi klinis pasien ketika berada di ruang ICU. Di dalam data klinis, terdapat data administrasi waktu kematian pasien. Data administrasi waktu kematian pasien akan digunakan untuk pengkategorisasian pasien pada saat tahap pengelompokan data, apakah pasien tersebut termasuk pada kategori prognosis baik atau buruk.

Jumlah total data yang tersedia di [physionet.org](http://physionet.org) mencapai  $\pm 10.828$  data pasien ICU. Tetapi pada penelitian hanya akan digunakan sebagian dari data tersebut. Data pasien ICU yang akan digunakan pada penelitian ini adalah data pasien MICU (*Medical Intensive Care Unit*) dewasa yang memiliki diagnosis *sepsis*. Sepsis merupakan kondisi dimana terjadi infeksi pada tubuh sehingga dapat mengancam jiwa. Pembatasan data yang digunakan untuk penelitian dilakukan dengan tujuan untuk mempersempit sebaran data, sehingga analisis dapat dilakukan dengan lebih fokus.

Dari total  $\pm 10.828$  data pasien ICU di [physionet.org](http://physionet.org), dilakukan penyaringan data agar sesuai dengan kriteria data yang telah ditetapkan. Sehingga diperoleh 206 data pasien yang terdiri dari 134 pasien dengan prognosis baik dan 72 pasien dengan prognosis buruk.

## 4.2. Praproses Data

Pada bagian ini akan dilakukan praproses data yang telah didapatkan dari hasil pengumpulan data pada [physionet.org](http://physionet.org). Praproses data yang dilakukan mencakup pengelompokan data berdasarkan kategori prognosis, melakukan konversi data sinyal EKG menjadi HRV, dan melakukan pemilihan data yang sesuai agar dapat diolah dan dilakukan analisis pada tahapan selanjutnya.

### 4.2.1. Pengelompokan Data

Data yang telah didapatkan akan dikelompokkan berdasarkan kategori prognosis pasien. Kategori prognosis pasien didasarkan dari catatan administrasi waktu kematian pasien. Pasien yang tidak memiliki catatan administrasi waktu kematian, merupakan pasien dengan kategori prognosis baik. Sedangkan pasien yang memiliki catatan administrasi waktu kematian, termasuk pada kategori prognosis buruk.

### 4.2.2. Konversi Sinyal EKG menjadi HRV

Data yang didapatkan pada saat pengumpulan data masih dalam bentuk sinyal EKG, sehingga tahapan selanjutnya yang dilakukan adalah melakukan konversi sinyal EKG menjadi HRV dengan menghitung nilai R-R intervalnya. Sinyal EKG untuk setiap pasien, terdiri 2 jenis tipe file yaitu .dat dan .hea. File .dat berisikan data sinyal digital berupa integer yang disimpan dalam bentuk biner. File .dat dapat dibaca menggunakan *WFDB package* pada *software* CYGWIN. Sedangkan file .hea merupakan file header yang berisikan informasi isi dari file-file sinyal yang terkait. File header digunakan oleh *software* ketika membaca file sinyal, untuk menentukan lokasi dan formatnya. Sehingga file .dat dan .hea merupakan satu kesatuan, karena file .dat tidak dapat diinterpretasikan tanpa adanya file header yang sesuai.

Dalam melakukan konversi sinyal EKG menjadi HRV dengan menggunakan *WFDB package* pada *CYGWIN*, juga dibutuhkan file anotasi yang akan mendeteksi setiap detak yang tercatat dengan label normal (N), sehingga dapat mendeteksi adanya kompleks QRS dan akan menyimpannya ke dalam file anotasi. File anotasi tersebut akan disimpan dengan *annotator name qrs*.

#### **4.2.3. Pemilihan Data**

Setelah data EKG dikonversi menjadi HRV, maka akan dilakukan pemilihan data sinyal HRV yang sesuai dan dapat digunakan untuk penelitian. Dikarenakan data awal biasanya merupakan *noise*, maka 10 data awal dari data sinyal tidak akan digunakan dalam penelitian ini. Data yang akan digunakan untuk penelitian harus memiliki jumlah data minimal sebanyak 900 data setelah pemotongan 10 data awal. Sehingga apabila memiliki jumlah data kurang dari 900 data, maka data tersebut tidak akan digunakan.

### **4.3. Perancangan Model Higher-Order Moments Detrended Fluctuation Analysis**

Pada tahapan ini akan dilakukan pembuatan model ekstraksi fitur dengan menggunakan metode HOMDFA. Metode HOMDFA dilakukan berdasarkan penelitian Yu Teng sebelumnya yang menerapkan metode tersebut untuk melakukan analisis fluktuasi data pada data *financial time series* [7]. Model akan dibuat menggunakan kode program pemrograman Python. Pembuatan kode program didasarkan pada tahapan dan perhitungan rumus metode ekstraksi fitur HOMDFA pada sub bab 2.2.5. Pada penelitian ini, ekstraksi fitur dilakukan dengan menggunakan 2 *scale* yang berbeda, yaitu *scale* berjumlah 5, 10, 15, 20, 25, dan 30. Sehingga percobaan ekstraksi fitur akan dilakukan dua kali, dan akan menghasilkan fitur untuk masing-masing *scale*-nya.

### 4.3.1. Perhitungan Integrasi Time Series

Tahapan awal pada metode HOMDFA, akan dilakukan perhitungan integrasi time series, dimana data akan dikonversi dari *noise like time series* menjadi *random walk like time series*. Sinyal HRV yang dihasilkan dari perhitungan R-R interval memiliki kriteria yang mirip dengan *noise like time series*, dimana memiliki sifat non stasioner yang sangat tinggi [19]. Apabila suatu data berbentuk *noise like time series*, dalam metode HOMDFA perlu dilakukan perubahan data menjadi *random walk like time series*. Konversi tersebut dilakukan dengan tujuan untuk memperjelas fluktuasi data karena dalam metode HOMDFA akan dilakukan analisis terhadap perbedaan fluktuasi data. Konversi dapat dilakukan dengan mengurangi data dengan nilai rata-rata data, kemudian dilakukan penjumlahan kumulatif sesuai dengan rumus [7] :

$$y(i) = \sum_{k=1}^i [x_k - x_{ave}], i = 1, \dots, N \quad (15)$$

### 4.3.2. Pembagian Segmen Data

Pada penelitian ini akan dilakukan pembagain segmen data, data akan dibagi menggunakan 5, 10, 15, 20, 25 dan 30 *scale* yang berbeda. Dalam melakukan pembagian data, akan diperlukan perhitungan untuk mencari nilai *scale*. Nilai *scale* merupakan nilai titik dimana data akan dibagi. Dalam menentukan nilai *scale*, pada penelitian ini akan digunakan perhitungan *log scale* berbasis 2. Perhitungan tersebut digunakan karena *log scale* cocok digunakan ketika data yang digunakan berjumlah banyak. Selain itu, hasil nilai *scale* dengan menggunakan perhitungan nilai *scale* akan memiliki jarak yang sama, sehingga akan mempermudah dalam memahami dan melakukan analisis data. Setelah diketahui nilai *scale*-nya, pembagian segmen dapat dilakukan dengan menggunakan rumus [7] :

$$\langle X_s(i) \rangle = \frac{1}{s} \sum_{i=1}^s X_s[(v-1)s + i], \quad v = 1, 2, \dots, N_s, \quad (16)$$

Nilai *scale* yang akan digunakan pada penelitian ini dapat dilihat pada Tabel 4.1.

**Tabel 4.1 Daftar Nilai Scale**

Jumlah Scale	Nilai Scale
5	21,43,92,197,421
10	21, 30, 43, 63, 92, 135, 197, 288, 421, 616
15	21,26,34,43,56,72,92 119,153,197,254,327,421,542,699
20	21, 25, 30, 36, 43, 52, 63, 76, 92, 111, 135, 163, 197, 238, 288, 348, 421, 509, 616, 745
25	21,24,28,32,37,43,50,59,68,79,92,107,125,145,169,197, ,229,267,310,361,421,490,570,664,773
30	21,23,26,30,34,38,43,49,56,63,72,81,92,105,119,135,1 53,173,197,223,254,288,327,371,421,478,542,616,699, 793

Penggunaan berbagai macam jumlah *scale* bertujuan untuk melihat efek dari masing-masing *scale* terhadap hasil yang diperoleh. Nilai minimum *scale* yang digunakan > 20 karena nilai *scale* < 10 memungkinkan terdapatnya *error* pada hasil perhitungan [20].

### 4.3.3. Perhitungan Nilai Skewness dan Kurtosis

Pada tahapan metode ekstraksi fitur HOMDFA, akan dilakukan perhitungan nilai *skewness* dan *kurtosis*, berdasarkan rumus perhitungan persamaan (17), (18), dan (19). Sebelum melakukan perhitungan nilai *skewness* dan *kurtosis*, akan dilakukan *fitting polynomial* untuk mencari tren data. Dengan mengetahui tren data, dapat dilakukan detren data yaitu menghilangkan tren jangka panjang, sehingga dapat dilakukan analisis dengan lebih fokus pada tren untuk setiap *scalanya*. Detren data dapat dilakukan dengan pengurangan data dengan

nilai *fit-line* hasil *polynomial fitting*. *Fitting polynomial* pada penelitian ini menggunakan *order 1*, dimana merupakan regresi linear.

Setelah dilakukan detren data, dapat dilakukan analisis perhitungan nilai *skewness* dan *kurtosis*. Nilai *skewness* digunakan untuk mengetahui nilai asimetri distribusi probabilitas dari variabel acak. Sehingga dapat diketahui kecenderungan suatu distribusi suatu nilai, apakah positif atau negatif. Sedangkan nilai *kurtosis* digunakan untuk mengetahui nilai perubahan dari *tailedness*. Sehingga dapat diketahui jarak perubahan dari satu nilai ke nilai lainnya. Perhitungan *skewness* dan *kurtosis* dapat dilakukan dengan rumus [7] :

a. *Skewness*

$$F_{SMDF}^2(\mathbf{s}, \mathbf{v}) = \gamma \left( \mathbf{X}_s^2(\mathbf{i}) \right) = \frac{\langle X_s(\mathbf{i}) - \langle X_s(\mathbf{i}) \rangle \rangle^3}{[\sigma^2(X_s(\mathbf{i}))]^{3/2}} \quad (17)$$

b. *Kurtosis*

$$F_{KMDF}^2(\mathbf{s}, \mathbf{v}) = \kappa \left( \mathbf{X}_s^2(\mathbf{i}) \right) = \frac{\langle X_s(\mathbf{i}) - \langle X_s(\mathbf{i}) \rangle \rangle^4}{[\sigma^2(X_s(\mathbf{i}))]^{3/2}} \quad (18)$$

$$\sigma^2(\mathbf{X}_s(\mathbf{i})) = \langle \mathbf{X}_s^2(\mathbf{i}) \rangle - \langle \mathbf{X}_s(\mathbf{i}) \rangle^2 \quad (19)$$

#### 4.3.4. Perhitungan Fungsi Fluktuasi

Hasil dari perhitungan *skewness* dan *kurtosis* selanjutnya akan dihitung fungsi fluktuasinya. Dengan melakukan perhitungan fungsi fluktuasi, dapat diketahui perubahan nilai pada variable *skewness* dan *kurtosis*. Sehingga dapat digunakan untuk melakukan analisis perubahan nilai fluktuasi antara pasien prognosis baik dan buruk. Perhitungan fungsi fluktuasi berdasarkan *skewness* dan *kurtosis* dapat dilakukan dengan rumus [7] :

$$F(s) = \left( \frac{1}{N_s} \sum_{v=1}^{2N_s} [F^2(s, v)] \right)^{\frac{1}{2}} \quad (20)$$

### 4.3.5. Perhitungan Local Scaling Exponent

Selanjutnya akan dilakukan perhitungan untuk menentukan nilai *local scaling exponent* berdasarkan *skewness* dan *kurtosis*. Dengan melakukan perhitungan *local scaling exponent*, dapat diketahui *scaling behavior* pada variabel *skewness* dan *kurtosis* pada *scale* yang berbeda. Sehingga dapat digunakan untuk melakukan analisis perbedaan *scaling behavior* pada data pasien prognosis baik dan buruk. Perhitungan nilai *local scaling exponent* didapatkan sesuai rumus [7] :

$$\alpha(s_k) = \frac{\log[F(s_{k+1})] - \log[F(s_{k-1})]}{\log[s_{k+1}] - \log[s_{k-1}]} \quad (21)$$

### 4.4. Perhitungan Parameter Input

Pada tahapan ini akan dilakukan perhitungan parameter input yang akan digunakan menjadi input klasifikasi ANN. Input pada tahapan ini berupa nilai fungsi fluktuasi serta *local scaling exponent* berdasarkan *skewness* dan *kurtosis*. Parameter yang digunakan pada penelitian ini yaitu berupa rata-rata fungsi fluktuasi dan *local scaling exponent* berdasarkan *skewness* dan *kurtosis*. Parameter tersebut digunakan karena pada metode HOMDFA dilakukan analisis terhadap perbedaan fluktuasi data, sehingga apabila data memiliki nilai fluktuasi yang berbeda, data memiliki kecenderungan memiliki nilai rata-rata yang berbeda pula. Selain itu, metode HOMDFA merupakan metode baru dimana penelitian terkait metode ini masih sedikit, sehingga belum adanya penelitian pasti tentang penetapan parameter yang tepat digunakan jika menggunakan metode HOMDFA. Sehingga pada penelitian ini akan mencoba untuk menerapkan perhitungan parameter berupa rata-rata. Perhitungan parameter akan dilakukan dengan pembagian data

untuk mengamati adanya perbedaan data pada *short term* dan *long term*.

#### **4.4.1. Pembagian Data**

Dalam melakukan perhitungan parameter input, data akan dibagi menjadi dua bagian. Hal tersebut dilakukan karena berdasarkan penelitian sebelumnya, terdapat perbedaan *range* data pada setengah data awal dan akhir hasil plot nilai fungsi fluktuasi dan *local scaling exponent* berdasarkan *skewness* dan *kurtosis*. Dengan melakukan pembagian data, dapat dilakukan analisis pada data *short term* dan *long term*, sehingga analisis dapat dilakukan dengan lebih detail. Pembagian data tersebut dilakukan berdasarkan *scale* pada Tabel 4.1. Untuk *scale* berjumlah 10, data akan dibagi menjadi data pada *scale*  $\leq 92$  dan data pada *scale*  $> 92$ . Sedangkan untuk *scale* berjumlah 20, data akan dibagi menjadi data pada *scale*  $\leq 111$  dan data pada *scale*  $> 111$ .

#### **4.4.2. Perhitungan Parameter Fungsi Fluktuasi berdasarkan Skewness**

Data fungsi fluktuasi berdasarkan *skewness* yang telah dibagi menjadi data *short term* dan *long term*, masing-masing akan dilakukan perhitungan rata-ratanya. Sehingga pada tahapan ini akan dihasilkan dua parameter yaitu rata-rata fungsi fluktuasi berdasarkan *skewness* pada *scale short term* dan rata-rata fungsi fluktuasi berdasarkan *skewness* pada *scale long term*.

#### **4.4.3. Perhitungan Parameter Fungsi Fluktuasi berdasarkan Kurtosis**

Data fungsi fluktuasi berdasarkan *kurtosis* yang telah dibagi menjadi data *short term* dan *long term*, masing-masing akan dilakukan perhitungan rata-ratanya. Sehingga pada tahapan ini akan dihasilkan dua parameter yaitu rata-rata fungsi fluktuasi berdasarkan *kurtosis* pada *scale short term* dan rata-rata fungsi fluktuasi berdasarkan *kurtosis* pada *scale long term*.

#### **4.4.4. Perhitungan Parameter *Local Scaling Exponent* berdasarkan *Skewness***

Data *local scaling exponent* berdasarkan *skewness* yang telah dibagi menjadi data *short term* dan *long term*, masing-masing akan dilakukan perhitungan rata-ratanya. Sehingga pada tahapan ini akan dihasilkan dua parameter yaitu rata-rata *local scaling exponent* berdasarkan *skewness* pada *scale short term* dan rata-rata *local scaling exponent* berdasarkan *skewness* pada *scale long term*.

#### **4.4.5. Perhitungan Parameter *Local Scaling Exponent* berdasarkan *Kurtosis***

Data *local scaling exponent* berdasarkan *kurtosis* yang telah dibagi menjadi data *short term* dan *long term*, masing-masing akan dilakukan perhitungan rata-ratanya. Sehingga pada tahapan ini akan dihasilkan dua parameter yaitu rata-rata *local scaling exponent* berdasarkan *kurtosis* pada *scale short term* dan rata-rata *local scaling exponent* berdasarkan *kurtosis* pada *scale long term*.

### **4.5. Uji Signifikansi**

Hasil perhitungan parameter yang didapatkan, kemudian dilakukan uji signifikansi untuk setiap parameternya. Uji signifikansi dilakukan dengan menggunakan metode *nonparametric*, Uji *Ranksum Wilcoxon* dengan menggunakan kode program python. Uji signifikansi dilakukan dengan tujuan untuk melihat apakah ada perbedaan signifikan untuk setiap data parameter antara pasien prognosis baik dan buruk. Parameter dinyatakan lolos uji signifikansi, apabila nilai perhitungan  $p\text{-value} < 0.05$ . Output dari tahap ini adalah nilai parameter yang signifikan, yang kemudian dijadikan input pada klasifikasi ANN.

#### **4.5.1. Uji Signifikansi Parameter Fungsi Fluktuasi berdasarkan Skewness**

Hasil perhitungan parameter rata-rata fungsi fluktuasi berdasarkan *skewness* pada *scale short term* akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value  $< 0.05$ , maka terdapat perbedaan signifikan antara keduanya, sehingga parameter tersebut dinyatakan lolos uji signifikansi. Begitupun dengan hasil perhitungan parameter rata-rata fungsi fluktuasi berdasarkan *skewness* pada *scale long term*, akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value  $< 0.05$ , maka terdapat perbedaan signifikan antara keduanya, maka parameter tersebut dinyatakan lolos uji signifikansi.

#### **4.5.2. Uji Signifikansi Parameter Fungsi Fluktuasi berdasarkan Kurtosis**

Hasil perhitungan parameter rata-rata fungsi fluktuasi berdasarkan *kurtosis* pada *scale short term* akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value  $< 0.05$ , maka terdapat perbedaan signifikan antara keduanya, sehingga parameter tersebut dinyatakan lolos uji signifikansi. Begitupun dengan hasil perhitungan parameter rata-rata fungsi fluktuasi berdasarkan *kurtosis* pada *scale long term*, akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value  $< 0.05$ , maka terdapat perbedaan signifikan antara keduanya, maka parameter tersebut dinyatakan lolos uji signifikansi.

#### **4.5.3. Uji Signifikansi Parameter *Local Scaling Exponent* berdasarkan Skewness**

Hasil perhitungan parameter rata-rata *local scaling exponent* berdasarkan *skewness* pada *scale short term* akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value < 0.05, maka terdapat perbedaan signifikan antara keduanya, sehingga parameter tersebut dinyatakan lolos uji signifikansi. Begitupun dengan hasil perhitungan parameter rata-rata *local scaling exponent* berdasarkan *skewness* pada *scale long term* akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value < 0.05, maka terdapat perbedaan signifikan antara keduanya, maka parameter tersebut dinyatakan lolos uji signifikansi.

#### **4.5.4. Uji Signifikansi Parameter *Local Scaling Exponent* berdasarkan Kurtosis**

Hasil perhitungan parameter rata-rata *local scaling exponent* berdasarkan *kurtosis* pada *scale short term* akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value < 0.05, maka terdapat perbedaan signifikan antara keduanya, sehingga parameter tersebut dinyatakan lolos uji signifikansi. Begitupun dengan hasil perhitungan parameter rata-rata *local scaling exponent* berdasarkan *kurtosis* pada *scale long term* akan dilakukan uji signifikansi dengan membandingkan parameter pada pasien prognosis baik dan buruk. Apabila hasil perhitungan p-value < 0.05, maka terdapat perbedaan signifikan antara keduanya, maka parameter tersebut dinyatakan lolos uji signifikansi.

## 4.6. Klasifikasi ANN

Pada tahapan ini dilakukan klasifikasi ANN dengan menggunakan data parameter yang lolos uji signifikansi. Data input ANN akan dibagi menjadi 2 dengan perbandingan 70:30 sebagai data pelatihan dan pengujian. Data input pada tahapan ini adalah data parameter yang lolos uji signifikansi. Arsitektur ANN yang digunakan berupa *multilayer perceptron backpropagation*, yang terdiri dari *input layer*, *hidden layer*, dan *output layer*. Klasifikasi ANN dilakukan dengan menggunakan *classifier multilayer perceptron* pada software WEKA. Hasil dari tahapan ini berupa model klasifikasi ANN terbaik yang didasarkan dari hasil *accuracy* model terbaik.

### 4.6.1. Pemodelan ANN

Dalam melakukan klasifikasi ANN, terlebih dahulu akan dilakukan penentuan jumlah node untuk masing masing layer (*input layer*, *hidden layer*, dan *output layer*). Jumlah node *input layer* akan disesuaikan dengan jumlah parameter yang lolos uji signifikansi untuk setiap *scale*-nya, sehingga jumlah node *input layer* untuk setiap *scale* akan berdeda. Untuk jumlah node pada *output layer* ditentukan berdasarkan jumlah output yang diinginkan. Pada penelitian ini, klasifikasi ANN akan menghasilkan output berupa hasil prognosis baik atau buruk, sehingga jumlah *output layer* pada model ANN berjumlah 1. Sedangkan untuk jumlah *hidden layer* akan dilakukan *trial error* dengan *range* nilai antara 1-8. Penentuan nilai *hidden node* didasarkan pada WEKA dalam menentukan nilai *hidden node*, yaitu 'i' = *attribute*, 'a' = (*attribute* + *class*)/2, 'o' = *class*, dan 't' = *attribute* + *class*. Hasil perhitungan nilai *hidden node* berdasarkan WEKA untuk setiap *scale* dapat dilihat pada Tabel 4.2. Berdasarkan pada Tabel 4.2, didapatkan nilai *hidden node* 2, 3, 4, 5, 6, dan 7. Tapi pada penelitian ini akan dicoba pula nilai *hidden node* > 7 yaitu 8, 9, 10, dan 11 sehingga dapat

dihasilkan lebih banyak model untuk dilakukan pelatihan dan pengujian untuk mendapatkan hasil yang paling baik.

**Tabel 4.2 Hidden Node berdasarkan WEKA**

Scale	Nilai Hidden Node	Deskripsi
5	i = 2 a = 2 o = 2 t = 4	'i' = <i>attribute</i> 'a' = $(\text{attribute} + \text{class})/2$ 'o' = <i>class</i> 't' = <i>attribute + class</i>
10	i = 4 a = 3 o = 2 t = 6	
15	i = 5 a = 2 o = 2 t = 4	
20	i = 5 a = 2 o = 3,4 t = 7	
25	i = 4 a = 3 o = 2 t = 6	
30	i = 2 a = 2 o = 2 t = 4	

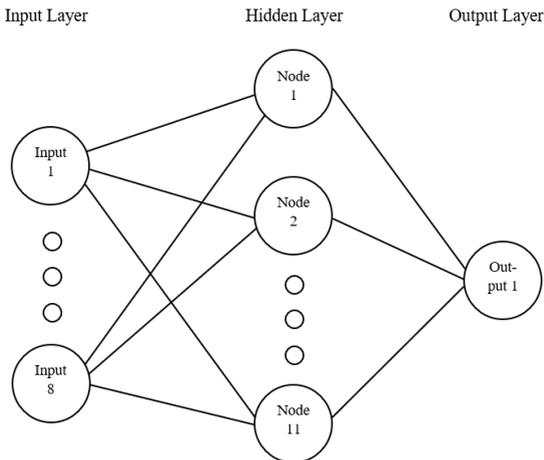
Pada model ANN juga terdapat *learning rate* dan *momentum*, dimana nilainya akan mengikuti nilai *default* pada *software* WEKA, yaitu untuk *learning rate* digunakan nilai 0.3, sedangkan untuk *momentum* menggunakan nilai 0.2.

Sedangkan untuk jumlah epoch didasarkan pada penelitian sebelumnya yang menggunakan epoch sebesar 3000 [8]. Rincian jumlah node beserta *range* nilai parameter ANN dapat dilihat pada Tabel 4.3.

**Tabel 4.3 Rancangan Parameter ANN**

Parameter	Nilai	Deskripsi
Input Node	1-8	Disesuaikan berdasarkan jumlah parameter yang lolos uji signifikansi untuk setiap <i>scale</i> -nya. Jenis variabel dapat bermacam-macam.
Hidden Node	2-11	<i>Trial error</i>
Output Node	1	Prognosis baik atau buruk
Learning Rate	0.3	Sesuai nilai default pada WEKA
Momentum	0.2	Sesuai nilai default pada WEKA
Epoch	3000	<i>Fix</i>

Gambar struktur model ANN yang digunakan untuk klasifikasi ANN pada penelitian ini dapat dilihat pada Gambar 4.1.



**Gambar 4.1 Struktur Model ANN**

#### 4.6.2. Pelatihan Model

Dari rancangan model ANN yang telah ditentukan, pada tahapan ini akan dilakukan pelatihan model menggunakan 70% data dari nilai parameter yang lolos uji signifikansi. Pelatihan model dilakukan dengan tujuan untuk melakukan pengenalan pola dalam melakukan klasifikasi. Pada tahapan ini akan dilakukan proses *trial and error* sesuai dengan rancangan model yang telah dibuat.

#### 4.6.3. Pengujian Model

Setelah melakukan pelatihan model, model akan diuji menggunakan data pengujian sebanyak 30% dari data nilai parameter yang lolos uji signifikansi. Dalam proses pengujian model, model akan coba digunakan untuk melakukan klasifikasi menggunakan data pengujian. Dari hasil klasifikasi yang dihasilkan oleh model tersebut, akan diketahui performa model dengan melakukan uji performa.

#### 4.6.4. Uji Performa

Hasil klasifikasi ANN kemudian akan dilakukan uji performa dengan menggunakan *confusion matrix* berupa perhitungan dari nilai *accuracy*, *sensitivity*, dan *specificity*. Digunakannya *sensitivity* dan *specificity* sebagai pengukuran performa menunjukkan bahwa jenis klasifikasi pada penelitian ini termasuk pada *biner classification*. Pengukuran performa menggunakan *recall* dan *precision* biasa digunakan untuk menunjukkan jenis klasifikasi yang dihasilkan berupa *multiclass classification*. Selain itu, uji performa juga akan dilakukan dengan ROC, dimana pengukuran performa dilakukan dengan menghitung luas area di bawah grafik ROC (AUC). Hasil uji performa dengan *confusion matrix* dan ROC digunakan untuk melakukan analisis dalam menentukan model ANN terbaik.

*(Halaman ini sengaja dikosongkan)*

## BAB V IMPLEMENTASI

Pada bab ini akan dijelaskan bagaimana pelaksanaan penelitian dilakukan, pembuatan model yang akan digunakan untuk melakukan analisis dan pemroses data, serta akan dijelaskan pula hambatan dan rintangan yang dialami selama pelaksanaan penelitian.

### 5.1. Pra Processing Data

Data yang telah dikumpulkan dari website pysionet, selanjutnya akan dikelompokkan berdasarkan kategori prognosis setiap pasien untuk dilakukan pra processing pada data tersebut. Pra processing data ini dilakukan menggunakan *syntax* dari *software* cygwin. Data sinyal EKG yang didapatkan, dapat dibaca dengan *syntax* :

```
rdsamp -r record -v
```

Dengan menggunakan *syntax* tersebut, dapat diketahui data apa saja beserta isinya yang tersimpan pada file. Hasil yang akan muncul dengan menggunakan *syntax* tersebut dapat dilihat pada Tabel 5.1.

**Tabel 5.1 Isi Record File Sinyal EKG**

#	II	III	AVR	V	RESP	PLETH
0	-32768	-32768	-32768	-32768	-32768	-32768
...	...	...	...	...	...	...
307	-226	-32768	2047	685	-32768	-32768
308	-349	-32768	2047	644	-32768	-32768
....	...	...	...	...	...	...

Dengan mengetahui isi dari file tersebut akan berguna ketika melakukan konversi sinyal menjadi HRV. Data yang akan

dilakukan konversi hanyalah data detak jantung, dimana data tersebut merupakan data pada kolom II.

### 5.1.1. Menambahkan File Anotasi

Sebelum melakukan konversi data sinyal EKG menjadi HRV, dibutuhkan annotation file yang akan berisikan kompleks QRS pada data sinyal EKG yang tersimpan. Untuk menambahkan file anotasi dapat dilakukan dengan *syntax*:

```
gqrs -r [recordname] -s II
```

*Syntax* tersebut dapat mendeteksi setiap detak jantung yang tercatat di dalam file dengan label normal (N), kemudian mendeteksi kompleks qrs, dan menyimpannya ke dalam file anotasi dengan *annotator* qrs. *Syntax* tersebut hanya akan membuat file anotasi untuk data sinyal pada kolom II.

Isi file anotasi dapat dilihat dengan menggunakan *syntax*:

```
rdann -r [recordname] -a [annotatorname] -v
```

*Syntax* tersebut akan membaca file anotasi berdasarkan record dan annotator yang telah ditentukan, kemudian akan mentranslasikannya menjadi output seperti pada Tabel 5.2.

**Tabel 5.2 Isi File Anotasi**

Time	Date	#	Type	Sub	Chan	Num	Aux
21:54:28.504	19/08/2134	304	N	0	0	127	
21:54:28.888	19/08/2134	352	N	0	0	27	
21:54:30.000	19/08/2134	491	N	0	0	37	
...	...	...	...	...	...	...	...

Pada kolom pertama Tabel 5.2, menunjukkan waktu anotasi. Kolom kedua menunjukkan tanggal notasi. Kolom ketiga

menunjukkan jumlah interval sampel dari awal catatan. Kolom ketiga menunjukkan label jenis detak apa yang dicatat. Kolom sub, chan, dan num tidak memiliki arti khusus. Sedangkan pada kolom terakhir terdapat informasi tambahan (jika ada).

### 5.1.2. Mengubah Sinyal EKG menjadi HRV

Setelah menambahkan file anotasi yang diperlukan sebelum melakukan konversi, tahapan selanjutnya adalah melakukan konversi sinyal EKG menjadi HRV. Konversi dapat dilakukan dengan menggunakan *syntax*:

```
ann2rr -r record -a annotator -p N -i s3 -V s3
      -w >fileoutput.rr
```

*Syntax* tersebut akan melakukan ekstraksi data interval dalam format teks, dari file anotasi dan menyimpannya dalam file dengan ekstensi *.rr*. Isi dari file yang dihasilkan dapat dilihat pada Tabel 5.3.

**Tabel 5.3 Hasil Konversi Sinyal EKG menjadi HRV**

Detik	R-R Interval	Status
0.000	2.728	N
2.728	0.544	N
3.272	0.768	N
...	...	...

Dari hasil konversi data sinyal EKG menjadi HRV, akan dihasilkan R-R interval, catatan detik untuk setiap R-R intervalnya, dan data status. Data status hanya menunjukkan label detak jantung yang tercatat. Data yang akan digunakan pada tahapan ekstraksi fitur hanyalah data R-R interval.

## 5.2. Pemilihan Data

Setelah melakukan konversi data sinyal EKG menjadi HRV, data tidak langsung dapat digunakan. Data harus dilakukan pengecekan terlebih dahulu agar memenuhi syarat yang telah ditetapkan.

Dalam penelitian ini, data R-R interval yang digunakan adalah 900 data setelah 10 data awal. Oleh karena itu akan dilakukan pengecekan data yang telah dikonversi. Apabila data < 900, maka data R-R interval pasien tersebut tidak akan digunakan. Pengecekan data dilakukan menggunakan Kode Program 5.1.

```
if len(rrInterval)<900:
    print('data<900',data2)
    print(len(rrInterval))
```

**Kode Program 5.1 Cek Data < 900**

Kode program tersebut akan melakukan pengecekan apakah jumlah data R-R interval < 900. Apabila data < 900, maka nama file dari data tersebut akan diprint. Data tersebut selanjutnya akan dihapus, karena tidak memenuhi syarat untuk digunakan.

## 5.3. Implementasi Higher-Order Moments Detrended Fluctuation Analysis

Data yang telah dilakukan pengecekan dan memenuhi syarat untuk dilakukan pengolahan data, akan dijadikan input untuk dilakukan ekstraksi fitur menggunakan metode HOMDFA. Model HOMDFA dibuat dengan menggunakan kode program pada python sesuai dengan tahapan dari metode tersebut.

### 5.3.1. Menghitung Integrasi Time Series

Tahapan awal dalam dalam metode HOMDFA adalah dilakukannya perubahan *noise like time series* menjadi *random walk time series*. Dengan menggunakan python, hal

tersebut dapat dilakukan dengan menggunakan Kode Program 5.2.

```
randWalk =
np.array(np.cumsum(rrInterval-
np.mean(rrInterval)))
```

#### Kode Program 5.2 Menghitung Integrasi Time Series

Pengubahan *noise like time series* menjadi *random walk time series* dilakukan dengan melakukan perhitungan rata-rata dari nilai time series, dimana pada penelitian ini adalah R-R interval. Kemudian setiap nilai dari R-R interval akan dikurangi hasil perhitungan rata-rata R-R interval. Hasil pengurangan tersebut selanjutnya akan dilakukan penjumlahan kumulatif, sehingga menghasilkan nilai *random walk*. Hasil perhitungan kemudian diplot dan ditampilkan dalam bentuk grafik, sehingga dapat digunakan untuk melakukan analisis dan melihat perbedaan antara R-R interval dan random walk dengan lebih mudah. Plot data dapat dilakukan dengan menggunakan Kode Program 5.3.

```
plt.plot(rrInterval)
plt.plot(tRandWalk)
```

#### Kode Program 5.3 Plot RR interval dan Random Walk

### 5.3.2. Membagi Segmen

Tahapan selanjutnya dalam metode HOMDFA adalah membagi data menjadi beberapa segmen dengan menggunakan 10 dan 20 *scale* yang berbeda. Dimana nilai skewness dan kurtosis akan dicari untuk setiap segmen. Untuk melakukan pembagian data, perlu dilakukannya pencarian nilai *scale*. Nilai *scale* merupakan skala pembagian data. Pencarian nilai *scale* dapat dilakukan dengan menggunakan Kode Program 5.4.

```

def scaleCal(tRW, step):
    logs = np.zeros((step))
    logs[0] = np.log2(20)
    i = 1
    N = len(tRW)
        ranges = np.log2(N)-logs[0]
        scale = ranges/step
        for i in range (1,step):
            logs[i] = logs[i-1]+scale
    scales=(np.ceil(2**logs)).astype('int')
    return logs,scales
logs,scales = scaleCal(tRandWalk,20)

```

#### Kode Program 5.4 Pencarian Nilai Scales

Pada baris pertama Kode Program 5.4, dilakukan inisiasi variabel input pada fungsi untuk melakukan perhitungan nilai *scale*. *tRW* merupakan nilai *random walk*, sedangkan *step* merupakan jumlah *scale* yang diinginkan. Pada baris kedua Kode Program 5.4, akan dibuat array berisi data sebanyak jumlah *scale* yang diinginkan. Jumlah *scale* yang akan digunakan pada penelitian ini adalah 10 dan 20. Pada baris ketiga Kode Program 5.4 didefinisikan jika nilai *scale* minimal adalah 20. Hal tersebut dilakukan karena jika nilai *scale* < 20, hasil perhitungan *skewness*, *kurtosis*, fungsi fluktuasi, dan *local scaling exponent* bernilai nan. Pada baris ketujuh Kode Program 5.4, dilakukan perhitungan jarak nilai tiap *scale*. Kemudian akan dilakukan *looping* sebanyak jumlah *scale* untuk mencari nilai tiap *scale*.

Setelah mendapatkan nilai *scale*, dilakukan pembagian pembagian data menjadi beberapa segmen dengan menggunakan Kode Program 5.5. Pembagian segmen data akan dilakukan sesuai dengan nilai *scale* hasil perhitungan menggunakan Kode Program 5.4.

```

for ns in range (0,len_scale):
    segment=int(np.floor(len(tRW)/s[ns]))

```

### Kode Program 5.5 Membagi Segmen Data

### 5.3.3. Menghitung Nilai *Skewness* dan *Kurtosis*

Tahap selanjutnya adalah melakukan perhitungan nilai *skewness* dan *kurtosis*. Data *random walk* yang telah dilakukan pembagian segmen akan dicari *trend*-nya dengan melakukan *fitting polynomial*. Kemudian akan dilakukan detren data untuk menghilangkan efek tren sehingga tidak mempengaruhi ketika melakukan analisis pola dan fluktuasi data. Setelah dilakukan detren data, nilai *skewness* dan *kurtosis* akan dicari untuk setiap segmennya. Kode program perhitungan nilai *skewness* dan *kurtosis* dapat dilihat pada Kode Program 5.6.

```

rangeIdx = int(v*s[ns])
Index = list(range(((v-1)*(s[ns]))+1),rangeIdx))
a = len(Index)
C = np.polyfit(Index,tRW[0:a],m)
fit = np.polyval(C,Index)
Xsi_1 = (tRW[0:a] - fit)
meanXsi = (np.mean(Xsi_1))
var = ((np.mean(Xsi_1**2))-(meanXsi**2))
skew = ((np.mean(Xsi_1-
(meanXsi))**3)/(var**(3/2))
kur = ((np.mean(Xsi_1-
(meanXsi))**4)/(var**(2))

```

### Kode Program 5.6 Menghitung Nilai *Skewness* dan *Kurtosis*

Pada baris pertama dan kedua Kode Program 5.6, dilakukan inisiasi nilai index yang akan digunakan untuk *fitting polynomial*. Baris keempat dan kelima Kode Program 5.6 merupakan tahapan untuk melakukan *polynomial fitting* dengan

order 1. Pada baris keempat, dilakukan pencarian nilai  $a$  dan  $b$  dari persamaan linear  $fit = ax + b$ . Setelah menemukan nilai  $a$  dan  $b$ , kemudian pada baris kelima dilakukan pencarian nilai  $fit$  dari persamaan linear  $fit = ax + b$ . Kemudian pada Kode Program 5.6 baris keenam akan dilakukan detren dengan mengurangi data *random walk* dengan hasil perhitungan nilai  $fit$ . Setelah melakukan detren data, pada baris ketujuh hingga kesembilan dilakukan perhitungan nilai *skewness* dan *kurtosis*. Nilai *skewness* dan *kurtosis* akan dihitung untuk setiap segmen datanya.

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

Pada tahap ini akan dilakukan perhitungan fungsi fluktuasi berdasarkan *skewness* dan *kurtosis*. Perhitungan fungsi fluktuasi dilakukan agar dapat mengetahui perubahan nilai pada variabel *skewness* dan *kurtosis*. Sehingga dapat diketahui perbandingan perubahan nilai *skewness* dan *kurtosis* pada pasien prognosis baik dan buruk. Fungsi fluktuasi dapat dihitung dengan menggunakan Kode Program 5.7.

```
Fs_S = np.sqrt((np.square(skewness)).mean())
Fs_K = np.sqrt((np.square(kurtosis)).mean())
```

#### Kode Program 5.7 Perhitungan Fungsi Fluktuasi

Baris pertama pada kode program 5.7, menghitung fungsi fluktuasi berdasarkan *skewness*. Sedangkan pada baris kedua, menghitung fungsi fluktuasi berdasarkan *kurtosis*. Perhitungan fungsi fluktuasi akan dilakukan *looping* sebanyak jumlah *scale* data, sehingga menghasilkan nilai fungsi fluktuasi untuk setiap *scale*-nya. Hasil perhitungan fungsi fluktuasi akan dijadikan input dalam perhitungan parameter. Data hasil perhitungan fungsi fluktuasi dapat diplot menjadi grafik dengan menggunakan Kode Program 5.8.

```

Fs_S = np.sqrt((np.square(skewness)).mean())
Fs_K = np.sqrt((np.square(kurtosis)).mean())

```

**Kode Program 5.8 Plot Fungsi Fluktuasi**

### 5.3.5. Menghitung Local Scaling Exponent berdasarkan *Skewness* dan *Kurtosis*

Pada tahapan ini akan dilakukan perhitungan *local scaling exponent* berdasarkan *skewness* dan *kurtosis*. Dengan melakukan perhitungan tersebut, dapat diketahui *scaling behaviour* pada variabel *skewness* dan *kurtosis*. Perhitungan tersebut dapat dilakukan dengan menggunakan Kode Program 5.9.

```

aSkew1      =      np.log10(Fs_Skew[j+1]) -
np.log10(Fs_Skew[j-1])
aSkew2 = np.log10(s[j+1]) - np.log10(s[j-1])
aSkew = aSkew1/aSkew2

aKur1      =      np.log10(Fs_Kur[j+1]) -
np.log10(Fs_Kur[j-1])
aKur2 = np.log10(s[j+1]) - np.log10(s[j-1])
aKur = aKur1/aKur2

```

**Kode Program 5.9 Perhitungan Local Scaling Exponent**

Baris pertama pada kode program 5.8, menghitung *local scaling exponent* berdasarkan *skewness*. Sedangkan pada baris kedua, menghitung *local scaling exponent* berdasarkan *kurtosis*. Hasil perhitungan *local scaling exponent* selanjutnya akan dijadikan input dalam perhitungan parameter. Data hasil perhitungan *local scaling exponent* dapat diplot menjadi grafik dengan menggunakan Kode Program 5.10.

```

Fs_S = np.sqrt((np.square(skewness)).mean())
Fs_K = np.sqrt((np.square(kurtosis)).mean())

```

**Kode Program 5.10 Plot Local Scaling Exponent**

## 5.4. Menghitung Parameter Input

Pada tahap ini akan dilakukan perhitungan parameter input yang akan diuji signifikansi dan digunakan sebagai input klasifikasi ANN. Parameter yang akan digunakan yaitu rata-rata data pada *scale short term* dan *scale long term* dari fungsi fluktuasi dan *local scaling exponent* berdasarkan *skewness* dan *kurtosis*.

### 5.4.1. Perhitungan Parameter Fungsi Fluktuasi berdasarkan Skewness

Pada tahapan ini akan dilakukan perhitungan parameter rata-rata fungsi fluktuasi berdasarkan *skewness*. Sebelum dilakukan perhitungan rata-rata, data akan dibagi berdasarkan *scale*. Sehingga pada tahapan ini akan dihasil dua parameter, yaitu rata-rata data pada *scale short term* dan *scale long term* fungsi fluktuasi berdasarkan *skewness*. Perhitungan dapat dilakukan dengan menggunakan Kode Program 5.11.

```

mean_Fs_Skew1=np.mean(Fs_Skew[:int((len(Fs_Skew))/2)], dtype=np.float64)

mean_Fs_Skew2=np.mean(Fs_Skew[int((len(Fs_Skew))/2):], dtype=np.float64)

```

**Kode Program 5.11 Perhitungan Parameter Rata-Rata Fungsi Fluktuasi berdasarkan Skewness**

Pada baris pertama Kode Program 5.11, dihitung rata-rata data pada *scale short term* fungsi fluktuasi berdasarkan *skewness*. Sedangkan, pada baris kedua Kode Program 5.11, dihitung rata-

rata-rata data pada *scale short term* fungsi fluktuasi berdasarkan *skewness*.

#### 5.4.2. Perhitungan Parameter Fungsi Fluktuasi berdasarkan Kurtosis

Pada tahapan ini akan dilakukan perhitungan parameter rata-rata fungsi fluktuasi berdasarkan *kurtosis*. Sebelum dilakukan perhitungan rata-rata, data akan dibagi berdasarkan *scale*. Sehingga pada tahapan ini akan dihasil dua parameter, yaitu rata-rata data pada *scale short term* dan *scale long term* fungsi fluktuasi berdasarkan *kurtosis*. Perhitungan dapat dilakukan dengan menggunakan Kode Program 5.12.

```
mean_Fs_Kur1=np.mean(Fs_Kur[:int((len(Fs_Kur))/2)], dtype=np.float64)

mean_Fs_Kur2=np.mean(Fs_Kur[int((len(Fs_Kur))/2):], dtype=np.float64)
```

#### Kode Program 5.12 Perhitungan Parameter Rata-Rata Fungsi Fluktuasi berdasarkan Kurtosis

Pada baris pertama Kode Program 5.12, dihitung rata-rata data pada *scale short term* fungsi fluktuasi berdasarkan *kurtosis*. Sedangkan, pada baris kedua Kode Program 5.12, dihitung rata-rata data pada *scale long term* fungsi fluktuasi berdasarkan *kurtosis*.

#### 5.4.3. Perhitungan Parameter *Local Scaling Exponent* berdasarkan *Skewness*

Pada tahapan ini akan dilakukan perhitungan parameter rata-rata *local scaling exponent* berdasarkan *skewness*. Sebelum dilakukan perhitungan rata-rata, data akan dibagi berdasarkan *scale*. Sehingga pada tahapan ini akan dihasil dua parameter, yaitu rata-rata data pada *scale short term* dan *scale long term*

*local scaling exponent* berdasarkan *skewness*. Perhitungan dapat dilakukan dengan menggunakan Kode Program 5.13.

```
mean_alpha_Skew1=np.mean(alpha_Skew[:int(
(len(alpha_Skew))/2)], dtype=np.float64)

mean_alpha_Skew2=np.mean(alpha_Skew[int((
len(alpha_Skew))/2):], dtype=np.float64)
```

**Kode Program 5.13 Perhitungan Parameter Rata-Rata Local Scaling Exponent berdasarkan Skewness**

Pada baris pertama Kode Program 5.13, dihitung rata-rata data pada *scale short term local scaling exponent* berdasarkan *skewness*. Sedangkan, pada baris kedua Kode Program 5.13, dihitung rata-rata data pada *scale long term local scaling exponent* berdasarkan *skewness*.

**5.4.4. Perhitungan Parameter Local Scaling Exponent berdasarkan Kurtosis**

Pada tahapan ini akan dilakukan perhitungan parameter rata-rata *local scaling exponent* berdasarkan *kurtosis*. Sebelum dilakukan perhitungan rata-rata, data akan dibagi berdasarkan *scale*. Sehingga pada tahapan ini akan dihasil dua parameter, yaitu rata-rata data pada *scale short term* dan *scale long term local scaling exponent* berdasarkan *kurtosis*. Perhitungan dapat dilakukan dengan menggunakan Kode Program 5.14.

Pada baris pertama Kode Program 5.14, dihitung rata-rata data pada *scale short term local scaling exponent* berdasarkan *kurtosis*. Sedangkan, pada baris kedua Kode Program 5.14, dihitung rata-rata data pada *scale long term local scaling exponent* berdasarkan *kurtosis*.

```

mean_alpha_Kur1=np.mean(alpha_Kur[:int((1
en(alpha_Kur))/2)], dtype=np.float64)

mean_alpha_Kur2=np.mean(alpha_Kur[int((1e
n(alpha_Kur))/2):], dtype=np.float64)

```

**Kode Program 5.14 Perhitungan Parameter Rata-Rata Local Scaling Exponent berdasarkan Kurtosis**

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

Ekstraksi fungsi dengan menggunakan model HOMDFA dilakukan sebanyak dua kali, karena pada penelitian ini dilakukan percobaan dengan dua jumlah *scale* yang berbeda (10 dan 20). Hal tersebut dilakukan untuk melakukan analisis terhadap kedua *scale* tersebut sehingga terdapat variasi data untuk digunakan pada klasifikasi ANN. *Scale* yang digunakan pada penelitian ini dapat dilihat pada Tabel 4.1.

## 5.6. Uji Signifikansi

Setelah melakukan percobaan dengan menggunakan jumlah *scale* yang berbeda, maka akan didapatkan nilai parameter input untuk masing-masing *scale*-nya. Sebelum dijadikan input pada klasifikasi ANN, perlu dilakukan uji signifikansi pada parameter untuk tiap *scale*-nya. Uji signifikansi akan dilakukan dengan menggunakan metode nonparametrik *Wilcoxon rank sum test*. Parameter akan dilakukan uji signifikansi dengan membandingkan masing-masing parameter pada data pasien prognosis baik dan buruk. Sebelum dilakukan uji signifikansi, perlu dipastikan jika data yang akan diuji tidak memiliki nilai nan ataupun *infinite*. Jika terdapat nilai nan atau *infinite*, maka data harus dibersihkan terlebih dahulu dengan cara menghilangkan nilai tersebut. Hal tersebut dilakukan karena pada uji *wilcoxon ranksum test* tidak dapat mendeteksi nilai

tersebut. Jika telah dilakukan pembersihan data, maka selanjutnya dapat dilakukan uji signifikansi menggunakan *wilcoxon ranksum test*. Pada python, uji signifikansi *wilcoxon ranksum test* dapat dilakukan dengan menggunakan Kode Program 5.15.

```
p1=ranksums(mean_Fs_Skew_Poor1,mean_Fs_Skew_Go
od1)

p2=ranksums(mean_Fs_Kur_Poor1,mean_Fs_Kur_Good
1)

p3=ranksums(mean_Alpha_Skew_Poor1,mean_Alpha_S
kew_Good1)

p4=ranksums(mean_Alpha_Kur_Poor1,mean_Alpha_Ku
r_Good1)

p5=ranksums(mean_Fs_Skew_Poor2,mean_Fs_Skew_Go
od2)

p6=ranksums(mean_Fs_Kur_Poor2,mean_Fs_Kur_Good
2)

p7=ranksums(mean_Alpha_Skew_Poor2,mean_Alpha_S
kew_Good2)

p8=ranksums(mean_Alpha_Kur_Poor2,mean_Alpha_Ku
r_Good2)
```

**Kode Program 5.15 Uji Signifikansi Wilcoxon Rank Sum Test**

Setiap variabel pada Kode Program 5.15, melakukan uji signifikansi pada parameter yang berbeda-beda. Variabel p1 merupakan uji signifikansi dengan membandingkan parameter setengah rata-rata awal fungsi fluktuasi berdasarkan *skewness* pada prognosis baik dan buruk. Variabel p2 merupakan uji signifikansi dengan membandingkan parameter setengah rata-rata awal fungsi fluktuasi berdasarkan *kurtosis* pada prognosis baik dan buruk. Variabel p3 merupakan uji signifikansi dengan

membandingkan parameter setengah rata-rata awal *local scaling exponent* berdasarkan *skewness* pada prognosis baik dan buruk. Variabel p4 merupakan uji signifikansi dengan membandingkan parameter setengah rata-rata awal *local scaling exponent* berdasarkan *kurtosis* pada prognosis baik dan buruk. Variabel p5 merupakan uji signifikansi dengan membandingkan parameter setengah rata-rata akhir fungsi fluktuasi berdasarkan *skewness* pada prognosis baik dan buruk. Variabel p6 merupakan uji signifikansi dengan membandingkan parameter setengah rata-rata akhir fungsi fluktuasi berdasarkan *kurtosis* pada prognosis baik dan buruk. Variabel p7 merupakan uji signifikansi dengan membandingkan parameter setengah rata-rata akhir *local scaling exponent* berdasarkan *skewness* pada prognosis baik dan buruk. Sedangkan, variabel p8 merupakan uji signifikansi dengan membandingkan parameter setengah rata-rata akhir *local scaling exponent* berdasarkan *kurtosis* pada prognosis baik dan buruk.

Hasil dari uji signifikansi adalah nilai p-value yang menentukan apakah nilai parameter tersebut lolos uji signifikan atau tidak. Apabila nilai p-value  $< 0.05$ , maka dapat dikatakan jika parameter tersebut lolos uji signifikan. Dari hal tersebut dapat didefinisikan jika nilai pada parameter yang lolos uji signifikan memiliki perbedaan nilai yang signifikan antara nilai parameter pada pasien prognosis baik dan buruk. Sehingga nilai tersebut layak dijadikan data input untuk klasifikasi ANN.

## 5.7. Implementasi Klasifikasi ANN

Pada tahapan ini akan dilakukan proses klasifikasi ANN mulai dari proses pembuatan model dengan melakukan *trial error* pada *hidden node* hingga melakukan uji performa untuk menentukan model terbaik. Proses klasifikasi dilakukan dengan menggunakan *software* WEKA. Skenario uji coba klasifikasi ANN dilakukan berdasarkan Tabel 5.4. Uji coba akan dilakukan untuk setiap *scale* dengan parameter input sesuai dengan jumlah

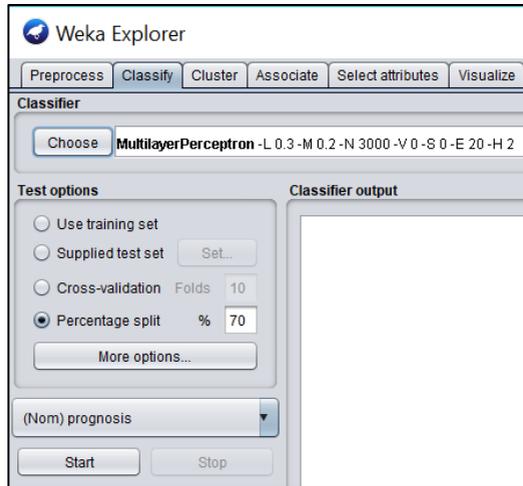
parameter yang lolos uji signifikansi pada data *scale* tersebut. Sedangkan untuk *ouput node*, *learning rate*, *momentum*, dan *epoch* memiliki nilai yang sama untuk *setiap scale*-nya. Untuk nilai parameter *hidden node* akan dilakukan *trial error* antara *range 2-11* untuk model *setiap scale*.

**Tabel 5.4 Skenario Parameter Uji Coba Klasifikasi ANN**

Parameter	Jumlah	Deskripsi
Input Node	Scale 5 = 2 Scale 10 = 4 Scale 15 = 2 Scale 20 = 5 Scale 25 = 4 Scale 30 = 2	Jumlah parameter yang lolos uji signifikansi
Hidden Node	2-11	Trial error
Output Node	1	Prognosis baik atau buruk
Learning Rate	0.3	Sesuai nilai default pada WEKA
Momentum	0.2	Sesuai nilai default pada WEKA
Epoch	3000	Fix

### 5.7.1. Klasifikasi ANN

Parameter yang telah lolos uji signifikansi pada *setiap scale* akan digunakan untuk melakukan klasifikasi ANN. Data pada parameter tersebut akan dibagi dengan perbandingan 70 : 30 untuk digunakan sebagai data pelatihan dan pengujian. Klasifikasi ANN dilakukan dengan menggunakan *software WEKA*. Konfigurasi klasifikasi ANN menggunakan WEKA dapat dilihat pada Gambar 5.1.



**Gambar 5.1 Konfigurasi WEKA**

Pada penelitian ini, *classifier* yang digunakan adalah *multilayer perceptron* dengan nilai *epoch* ditentukan sebesar 3000, nilai *hidden node* dilakukan *trial error* antara range 2-11, sedangkan untuk nilai lainnya seperti momentum dan *learning rate* mengikuti konfigurasi default pada WEKA. Pada menu *test option* WEKA, dipilih *percentage split* dengan nilai 70%. Pada WEKA, hal tersebut akan langsung otomatis membagi data pelatihan dan pengujian dengan perbandingan 70:30.

### **5.7.2. Uji Performa**

Pada tahapan ini akan dilakukan uji performa pada setiap model klasifikasi ANN untuk memilih model klasifikasi ANN yang terbaik. Uji performa pada penelitian ini menggunakan *confusion matrix* dan ROC dengan menggunakan *software WEKA*. Pada *confusion matrix*, pengukuran performa suatu model dapat dilakukan dengan menghitung nilai *accuracy*, *sensitivity*, dan *specificity*. Sedangkan pada ROC, dilakukan dengan menghitung luas area di bawah kurva ROC (AUC).

Contoh dari hasil *confusion matrix* dan AUC pada WEKA dapat dilihat pada Gambar 5.2.

```

=== Summary ===
Correctly Classified Instances      40           64.5161 %
Incorrectly Classified Instances    22           35.4839 %
Kappa statistic                    0.14
Mean absolute error                 0.3751
Root mean squared error            0.4746
Relative absolute error            63.9401 %
Root relative squared error        103.323 %
Total Number of Instances          62

=== Detailed Accuracy By Class ===
                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                -----  -----  -
                0.733  0.588  0.767  0.733  0.750  0.140  0.573  0.778  good
                0.412  0.267  0.368  0.412  0.389  0.140  0.573  0.426  poor
Weighted Avg.   0.645  0.500  0.658  0.645  0.651  0.140  0.573  0.682

=== Confusion Matrix ===
  a  b  <-- classified as
33 12 | a = good
10  7 | b = poor

```

**Gambar 5.2 Contoh Hasil Uji Performa WEKA**

Berdasarkan pada Gambar 5.2, dapat dilihat jika hasil perhitungan *sensitivity* dan *specificity* tidak ada. Hal tersebut karena pada WEKA menggunakan penamaan perhitungan yang berbeda pada *sensitivity*. Pada WEKA, nilai *sensitivity* sama dengan *recall*. Sedangkan untuk nilai *specificity* memang tidak dilakukan perhitungan pada WEKA, sehingga akan dilakukan perhitungan secara manual dengan menggunakan EXCEL. *Specificity* dapat dihitung dengan melakukan pengurangan pada bilangan satu dengan nilai *FP rate*. Perbedaan penggunaan pengukuran tersebut dilakukan untuk membedakan jika klasifikasi pada penelitian ini termasuk pada *binary classification*.

## **BAB VI**

### **HASIL DAN PEMBAHASAN**

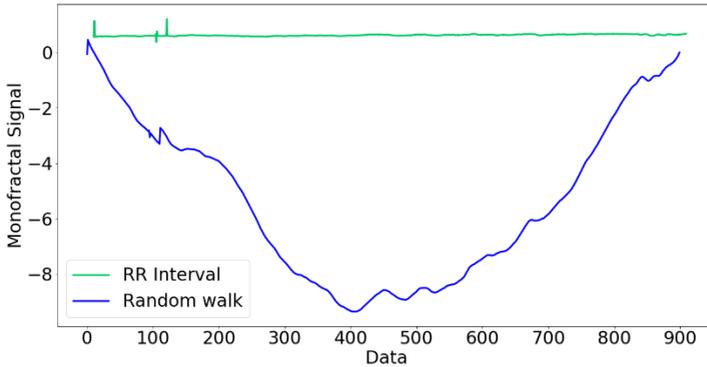
Pada bab ini akan berisikan data hasil percobaan, serta penjelasan tentang hasil implementasi perancangan penelitian. Hasil dan pembahasan pada bab ini menyangkut tentang hasil ekstraksi fitur menggunakan metode HOMDFA, hasil uji signifikansi, dan juga hasil klasifikasi ANN.

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

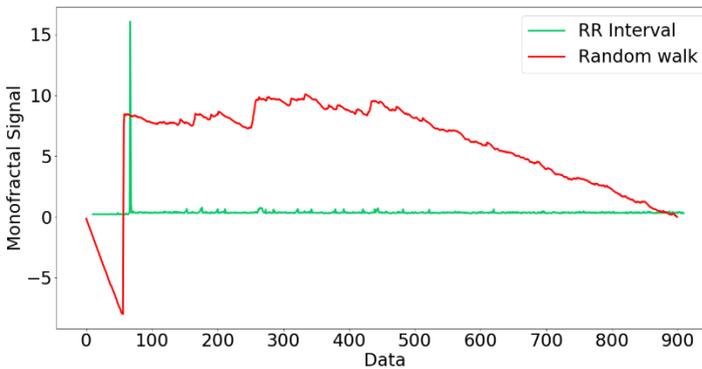
Pada tahapan awal metode ekstraksi fitur dengan menggunakan HOMDFA, dilakukan perhitungan integrasi *time series* yaitu melakukan konversi dari *noise like time series* menjadi *random walk*. Metode HOMDFA dilakukan dengan tujuan melakukan analisis terhadap fluktuasi data. Oleh karena itu, konversi dari *noise like time series* menjadi *random walk* diperlukan untuk memperjelas adanya fluktuasi data, sehingga dapat mempermudah analisis. Grafik perbandingan R-R interval dan *walk like time series* pada pasien prognosis baik dapat dilihat pada Gambar 6.1, sedangkan untuk pasien prognosis buruk dapat dilihat pada Gambar 6.2. Dari Gambar 6.1 dan Gambar 6.2, dapat diamati apabila pada *noise like ime series* (R-R interval) tidak terlalu terlihat adanya fluktuasi pada data. Tapi setelah dilakukan konversi menjadi *walk like time series*, fluktuasi datanya dapat lebih terlihat sehingga lebih mudah untuk diamati.

Data yang telah dilakukan konversi menjadi *random walk like time series* selanjutnya akan digunakan untuk melakukan perhitungan sehingga dapat diketahui nilai *skewness* dan *kurtosis* pada data. Nilai *skewness* digunakan untuk mengetahui nilai asimetri distribusi probabilitas dari variabel acak. Sedangkan nilai *kurtosis* digunakan untuk mengetahui nilai perubahan dari *tailedness*. Dari masing-masing nilai tersebut,

selanjutnya akan dilakukan pengamatan terhadap fluktuasi dan *scaling behaviour* pada data dengan menggunakan fungsi fluktuasi dan *local scaling exponent*.



**Gambar 6.1 R-R Interval dan Random Walk pada Pasien Prognosis Baik**

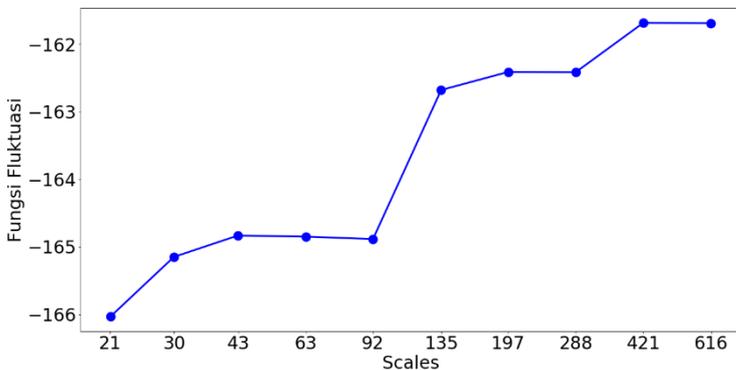


**Gambar 6.2 R-R Interval dan Random Walk pada Pasien Prognosis Buruk**

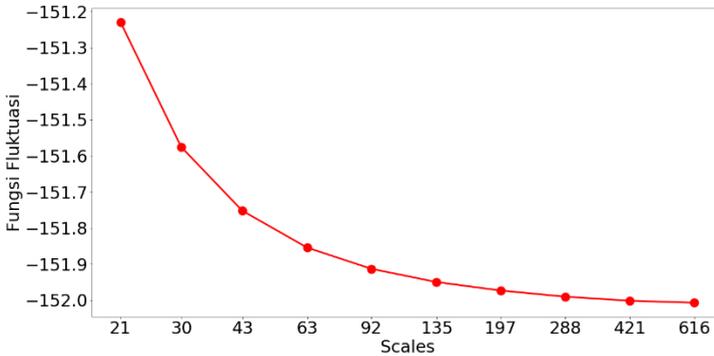
Setelah melakukan konversi data menjadi *random walk*. Data *random walk* digunakan untuk melakukan perhitungan nilai fungsi fluktuasi dan *local scaling exponent* berdasarkan

*skewness* dan *kurtosis*. Hasil dari perhitungan tersebut kemudian diplot menjadi grafik untuk dilakukan analisis. Hasil dari plot fungsi fluktuasi dan *local scaling exponent* berdasarkan *skewness* dan *kurtosis* untuk masing-masing prognosis pasien dapat dilihat pada Gambar 6.3 hingga Gambar 6.10. Selain itu, analisis data juga dilakukan dengan melakukan perhitungan rata-rata dari rata-rata data hasil perhitungan fungsi fluktuasi dan *local scaling exponent* pada pasien prognosis baik dan buruk. Perhitungan rata-rata akan dilakukan untuk data total, data *short term*, dan data *long term*.

Gambar 6.3 merupakan plot fungsi fluktuasi berdasarkan *skewness* pada pasien prognosis baik. Sedangkan Gambar 6.4 merupakan plot fungsi fluktuasi berdasarkan *skewness* pada pasien prognosis buruk. Nilai y-axis pada plot merupakan nilai dari perhitungan fungsi fluktuasi, sedangkan nilai x-axis merupakan nilai *scales* dengan jumlah *scales* sebanyak 10.



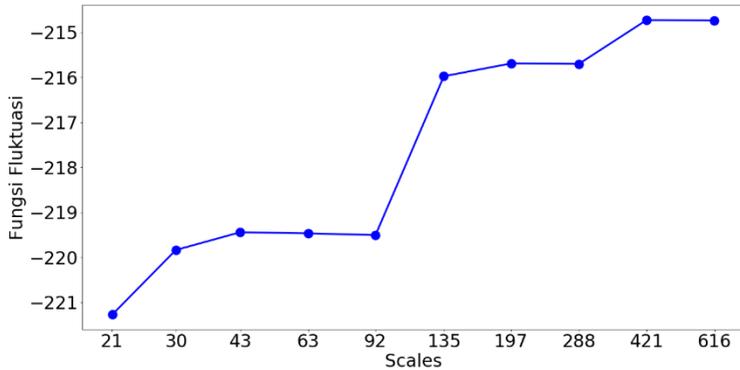
**Gambar 6.3 Fungsi Fluktuasi berdasarkan *Skewness* pada Pasien Prognosis Baik. Nilai rata-rata total =  $8,92 \times e^{-50}$ , Rata-Rata *Short Term* =  $2,01 \times e^{-50}$ , Rata-Rata *Long Term* =  $1,58 \times e^{-50}$**



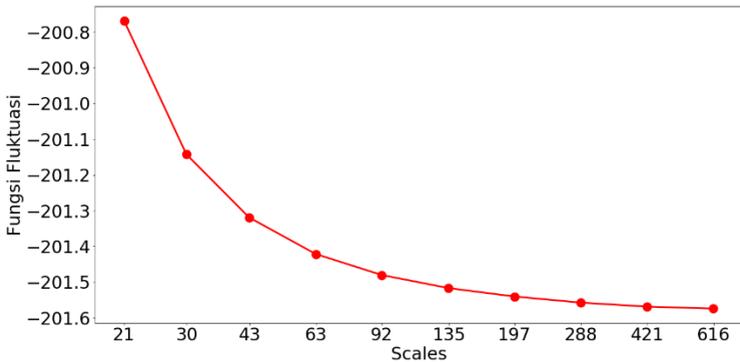
**Gambar 6.4 Fungsi Fluktuasi berdasarkan *Skewness* Pasien Prognosis Buruk. Rata-Rata Total =  $2,007 \times e^{-46}$ , Rata-Rata *Short Term* =  $2,24 \times e^{-46}$ , Rata-Rata *Long Term* =  $1,77 \times e^{-46}$**

Apabila dilakukan analisis pada Gambar 6.3 dan Gambar 6.4, data fungsi fluktuasi berdasarkan *skewness* pada pasien prognosis baik cenderung lebih rendah daripada pasien prognosis buruk. Hal tersebut dapat dibuktikan dengan nilai rata-rata total pada fungsi fuktuasi berdasarkan *skewness* pada prognosis baik bernilai  $8,92 \times e^{-50}$ , sedangkan pada prognosis buruk bernilai  $2,007 \times e^{-46}$ .

Selain itu, plot data pada Gambar 6.3 cenderung mengalami peningkatan, sedangkan plot data pada Gambar 6.4, cenderung mengalami penurunan. Hal tersebut dapat dibuktikan dengan pengamatan lebih detail pada data *short term* dan *long term* pada fungsi fluktuasi berdasarkan *skewness*. Pada fungsi fluktuasi berdasarkan *skewness* pada prognosis baik, rata-rata data pada *short term* ( $2,01 \times e^{-50}$ ) lebih rendah daripada rata-rata data pada *long term* ( $1,58 \times e^{-65}$ ). Sedangkan pada prognosis buruk, nilai rata-ratanya berkebalikan dari prognosis baik. Pada prognosis buruk, rata-rata data pada *short term* ( $2,24 \times e^{-46}$ ) lebih tinggi daripada rata-rata data pada *long term*-nya ( $1,77 \times e^{-46}$ ).



**Gambar 6.5 Fungsi Fluktuasi berdasarkan *Kurtosis* Pasien Prognosis Baik. Rata-Rata Total =  $8,25 \times e^{-66}$ , Rata-Rata *Short Term* =  $6,96 \times e^{-67}$ , Rata-Rata *Long Term* =  $1,58 \times e^{-65}$**



**Gambar 6.6 Fungsi Fluktuasi berdasarkan *Kurtosis* Pasien Prognosis Buruk. Rata-Rata Total =  $2,41 \times e^{-61}$ , Rata-Rata *Short Term* =  $2,7 \times e^{-61}$ , Rata-Rata *Long Term* =  $2,12 \times e^{-61}$**

Gambar 6.5 merupakan plot fungsi fluktuasi berdasarkan *kurtosis* pada pasien prognosis baik. Sedangkan Gambar 6.6 merupakan plot fungsi fluktuasi berdasarkan *kurtosis* pada pasien prognosis buruk. Nilai y-axis pada plot merupakan nilai

dari perhitungan fungsi fluktuasi, sedangkan nilai x-axis merupakan nilai *scales* dengan jumlah *scales* sebanyak 10.

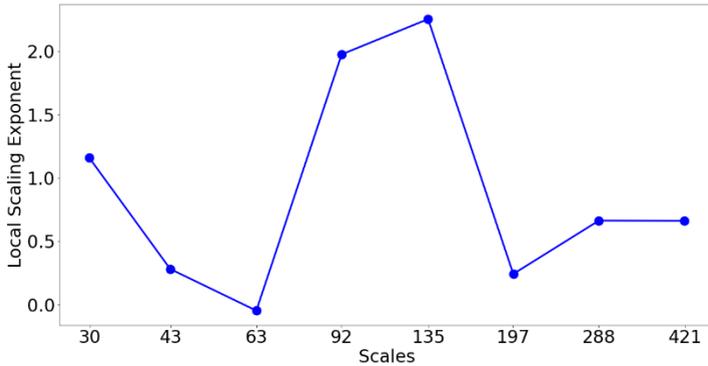
Apabila dilakukan analisis pada Gambar 6.5 dan Gambar 6.6, data fungsi fluktuasi berdasarkan *kurtosis* pada pasien prognosis baik cenderung lebih rendah daripada pasien prognosis buruk. Hal tersebut dapat dibuktikan dengan nilai rata-rata total pada fungsi fluktuasi berdasarkan *kurtosis* pada prognosis baik bernilai  $8,25 \times e^{-66}$ , sedangkan pada prognosis buruk bernilai  $2,41 \times e^{-61}$ .

Selain itu, plot data pada Gambar 6.5 cenderung mengalami peningkatan, sedangkan plot data pada Gambar 6.6, cenderung mengalami penurunan. Hal tersebut dapat dibuktikan dengan pengamatan lebih detail pada data *short term* dan *long term* pada fungsi fluktuasi berdasarkan *kurtosis*. Pada fungsi fluktuasi berdasarkan *kurtosis* pada prognosis baik, rata-rata data pada *short term* ( $6,96 \times e^{-67}$ ) lebih rendah daripada rata-rata data pada *long term* ( $1,58 \times e^{-65}$ ). Sedangkan pada prognosis buruk, nilai rata-ratanya berkebalikan dari prognosis baik. Pada prognosis buruk, rata-rata data pada *short term* ( $2,7 \times e^{-61}$ , ) lebih tinggi daripada rata-rata data pada *long term*-nya ( $2,12 \times e^{-61}$ ).

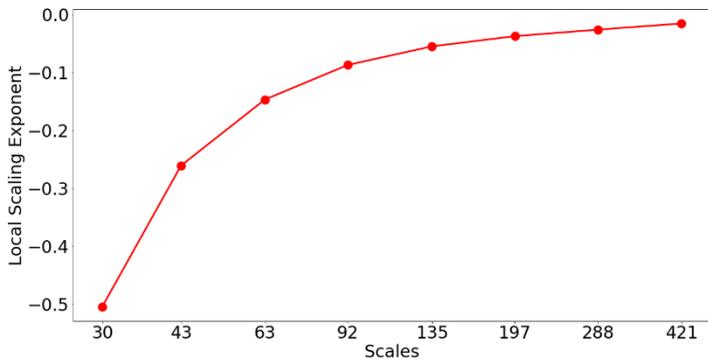
Gambar 6.7 merupakan plot *local scaling exponent* berdasarkan *skewness* pada pasien prognosis baik. Gambar 6.8 merupakan plot *local scaling exponent* berdasarkan *skewness* pada pasien prognosis buruk. Nilai y-axis pada plot merupakan nilai dari perhitungan *local scaling exponent*, sedangkan nilai x-axis merupakan nilai *scales* dengan jumlah *scales* sebanyak 10.

Apabila dilakukan analisis pada Gambar 6.7 dan Gambar 6.8, data *local scaling exponent* berdasarkan *skewness* pada pasien prognosis baik cenderung lebih tinggi daripada pasien prognosis buruk. Hal tersebut dapat dibuktikan dengan nilai rata-rata total pada fungsi fluktuasi berdasarkan *skewness* pada

prognosis baik bernilai 0,3, sedangkan pada prognosis buruk bernilai 0,18.



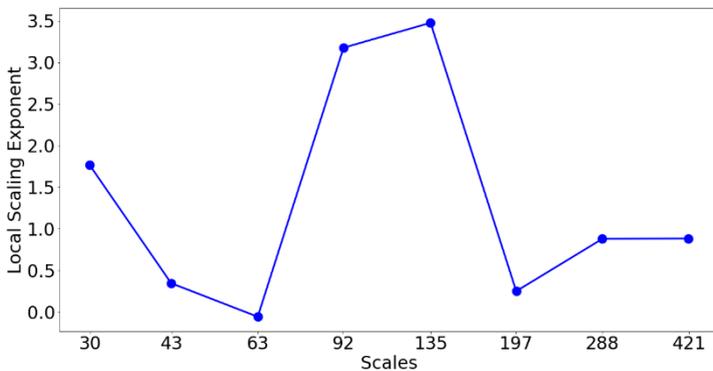
**Gambar 6.7** *Local Scaling Exponent* berdasarkan *Skewness* Pasien Prognosis Baik. Rata-Rata Total = 0,9, Rata-Rata *Short Term* = 0,84 Rata-Rata *Long Term* = 0,96



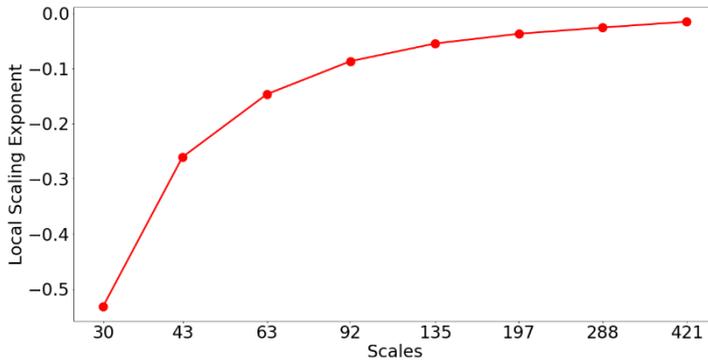
**Gambar 6.8** *Local Scaling Exponent* berdasarkan *Skewness* Pasien Prognosis Buruk. Rata-Rata Total = -0,14, Rata-Rata *Short Term* = -0,25 Rata-Rata *Long Term* = -0,033

Apabila dilakukan analisis lebih detail pada data *short term* dan *long term* pada *local scaling exponent* berdasarkan *skewness*. Pada prognosis baik, rata-rata data pada *short term* bernilai 0,86, sedangkan pada prognosis buruk bernilai lebih rendah yaitu  $-0,14$ . Untuk rata-rata data *long term* pada *local scaling exponent* berdasarkan *skewness* pada prognosis baik, bernilai 0,96. Sedangkan, pada prognosis buruk bernilai lebih rendah juga  $-0,033$ . Hal tersebut membuktikan bahwa pada *local scaling exponent* berdasarkan *skewness*, data *short term* maupun *long term* pada prognosis baik cenderung lebih tinggi daripada pada prognosis buruk.

Gambar 6.9 merupakan plot *local scaling exponent* berdasarkan *skewness* pada pasien prognosis baik. Gambar 6.10 merupakan plot *local scaling exponent* berdasarkan *skewness* pada pasien prognosis buruk. Nilai y-axis pada plot merupakan nilai dari perhitungan *local scaling exponent*, sedangkan nilai x-axis merupakan nilai *scales* dengan jumlah *scales* sebanyak 10.



**Gambar 6.9** *Local Scaling Exponent* berdasarkan *Kurtosis* Pasien Prognosis Baik. Rata-Rata Total = 1,34, Rata-Rata *Short Term* = 1,3 Rata-Rata *Long Term* = 1,37



**Gambar 6.10 Local Scaling Exponent berdasarkan Kurtosis Pasien Prognosis Buruk. Rata-Rata Total =  $-0,14$ , Rata-Rata *Short Term* =  $-0,26$  Rata-Rata *Long Term* =  $-0,03$**

Apabila dilakukan analisis pada Gambar 6.9 dan Gambar 6.10, data *local scaling exponent* berdasarkan *kurtosis* pada pasien prognosis baik cenderung lebih tinggi daripada pasien prognosis buruk. Hal tersebut dapat dibuktikan dengan nilai rata-rata total pada fungsi fuktuasi berdasarkan *kurtosis* pada prognosis baik bernilai 0,3, sedangkan pada prognosis buruk bernilai 0,18.

Apabila dilakukan analisis lebih detail pada data *short term* dan *long term* pada *local scaling exponent* berdasarkan *kurtosis*. Pada prognosis baik, rata-rata data pada *short term* bernilai 1,3, sedangkan pada prognosis buruk bernilai lebih rendah yaitu  $-0,26$ . Untuk rata-rata data *long term* pada *local scaling exponent* berdasarkan *kurtosis* pada prognosis baik, bernilai 1,37. Sedangkan, pada prognosis buruk bernilai lebih rendah juga  $-0,03$ . Hal tersebut membuktikan bahwa pada *local scaling exponent* berdasarkan *kurtosis*, data *short term* maupun *long term* pada prognosis baik cenderung lebih tinggi daripada pada prognosis buruk.

Hasil perhitungan rata-rata dari nilai short term dan log term secara keseluruhan untuk tiap *scale* dapat dilihat pada LAMPIRAN A dan LAMPIRAN .

Dari hasil perhitungan fungsi fluktuasi dan *local scaling exponent*, selanjutnya akan dilakukan perhitungan parameter yang akan digunakan untuk input pada tahapan klasifikasi ANN. Berdasarkan hasil pengamatan untuk setiap plot data *short term* dan *long term*, terdapat perbedaan kecenderungan fluktuasi data. Sehingga data dapat dilakukan analisis lebih lanjut dengan membagi data menjadi dua bagian, yaitu data *short term* dan *long term*.

Dari hasil pembagian data, selanjutnya akan dilakukan perhitungan rata-rata data untuk setiap *scale*. Digunakannya perhitungan rata-rata pada penelitian ini karena berdasarkan hasil analisis yang telah dijelaskan, data antara prognosis baik dan buruk memiliki kecenderungan fluktuasi data yang berbeda, sehingga nilai rata-rata pada data juga akan berbeda. Dari hasil perhitungan rata-rata untuk setiap *scale*, didapatkan 8 parameter yaitu fungsi fluktuasi berdasarkan *skewness* untuk *short term*, fungsi fluktuasi berdasarkan *skewness* untuk *long term*, fungsi fluktuasi berdasarkan *kurtosis* untuk *short term*, fungsi fluktuasi berdasarkan *kurtosis* untuk *long term*, *local scaling exponent* berdasarkan *skewness* untuk *short term*, *local scaling exponent* berdasarkan *skewness* untuk *long term*, *local scaling exponent* berdasarkan *kurtosis* untuk *short term*, dan *local scaling exponent* berdasarkan *skewness* untuk *long term*.

## **6.2. Hasil Uji Signifikansi**

Pada sub bab ini akan berisikan hasil serta penjelasan tentang uji signifikansi parameter yang didapatkan dari ekstraksi fitur menggunakan HOMDFA. Hasil uji signifikansi data akan dibagi menjadi dua, yaitu uji signifikansi parameter data dengan *scale* 5, 10, 15, 20, 25, dan 30.

### 6.2.1. Uji Signifikansi Data dengan Scale 5

Setelah melakukan ekstraksi fitur menggunakan HOMDFA, parameter yang dihasilkan sebanyak 8 parameter. Parameter tersebut berasal dari rata-rata data pada  $scale < 92$  dan  $scale \geq 92$  pada fungsi fluktuasi dan *local scaling exponent*. Hasil uji signifikansi *Wilcoxon ranksum test* pada parameter data dengan scale 5 dapat dilihat pada Tabel 6.1.

Pada Tabel 6.1 terdapat kolom parameter yang berisikan setiap parameter hasil dari ekstraksi fitur menggunakan HOMDFA, pada kolom kedua terdapat nilai p-value dari hasil uji signifikansi menggunakan *Wilcoxon ranksum test*, sedangkan pada kolom ketiga terdapat keterangan dari hasil uji signifikansi yang menjelaskan apakah parameter terkait lolos uji signifikansi atau tidak.

**Tabel 6.1 Hasil Uji Signifikansi Parameter Scale 5**

Parameter	P-value	Keterangan
Rata-rata Fs Skewness pada $scale < 92$	0.09	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale < 92$	0.06	Tidak Signifikan
Rata-Rata Local Scaling Exponent Skewness pada $Scale < 92$	0.004	Signifikan
Rata-Rata Local Scaling Exponent Kurtosis pada $Scale < 92$	0.003	Signifikan
Rata-Rata Fungsi Fluktuasi Skewness $Scale \geq 92$	0.78	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale \geq 92$	0.87	Tidak Signifikan

Parameter	P-value	Keterangan
Rata-Rata Local Scaling Exponent Skewness <i>Scale</i> $\geq 92$	0.35	Tidak Signifikan
Rata-Rata Local Scaling Exponent Kurtosis <i>Scale</i> $\geq 92$	0.38	Tidak Signifikan

Percobaan pertama uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada *scale*  $< 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.09, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter rata-rata fungsi fluktuasi pada *scale*  $< 92$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedua uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada *scale*  $< 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.06, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi *scale*  $< 92$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketiga uji signifikansi, dilakukan pada parameter *local scaling exponent* pada *scale*  $< 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.004, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada *scale*  $< 92$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan keempat uji signifikansi, dilakukan pada parameter *local scaling exponent* pada *scale*  $< 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.03, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada *scale*  $< 92$  berdasarkan *kurtosis* lolos uji

signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kelima uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.78, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 92$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keenam uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.87, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 92$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketujuh uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.35, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 92$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedelapan uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.38, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 92$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Dari delapan percobaan menggunakan data parameter dengan  $scale < 92$  dihasilkan dua parameter yang lolos uji signifikansi yaitu parameter *local scaling exponent* berdasarkan *skewness* pada  $scale < 92$  dan *local scaling exponent* berdasarkan *kurtosis* pada  $scale < 92$ .

### 6.2.2. Uji Signifikansi Data dengan Scale 10

Setelah melakukan ekstraksi fitur menggunakan HOMDFA, parameter yang dihasilkan sebanyak 8 parameter. Parameter tersebut berasal dari rata-rata data pada *scale*  $\leq 92$  dan *scale*  $> 92$  pada fungsi fluktuasi dan *local scaling exponent*. Hasil uji signifikansi *Wilcoxon ranksum test* pada parameter data dengan *scale* 10 dapat dilihat pada Tabel 6.2.

**Tabel 6.2 Hasil Uji Signifikansi Parameter Scale 10**

Parameter	P-value	Keterangan
Rata-rata Fs Skewness pada <i>scale</i> $\leq 92$	0.14	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada <i>Scale</i> $\leq 92$	0.16	Tidak Signifikan
Rata-Rata Local Scaling Exponent Skewness pada <i>Scale</i> $\leq 92$	0.02	Signifikan
Rata-Rata Local Scaling Exponent Kurtosis pada <i>Scale</i> $\leq 92$	0.01	Signifikan
Rata-Rata Fungsi Fluktuasi Skewness <i>Scale</i> $> 92$	0.53	Tidak signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada <i>Scale</i> $> 92$	0.38	Tidak signifikan
Rata-Rata Local Scaling Exponent Skewness <i>Scale</i> $> 92$	0.02	Signifikan
Rata-Rata Local Scaling Exponent Kurtosis <i>Scale</i> $> 92$	0.02	Signifikan

Pada Tabel 6.2 terdapat kolom parameter yang berisikan setiap parameter hasil dari ekstraksi fitur menggunakan HOMDFA, pada kolom kedua terdapat nilai p-value dari hasil uji signifikansi menggunakan *Wilcoxon ranksum test*, sedangkan

pada kolom ketiga terdapat keterangan dari hasil uji signifikansi yang menjelaskan apakah parameter terkait lolos uji signifikansi atau tidak.

Percobaan pertama uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \leq 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.14, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter rata-rata fungsi fluktuasi pada  $scale < 92$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedua uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \leq 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.16, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi  $scale \leq 92$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketiga uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \leq 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.02, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \leq 92$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan keempat uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \leq 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.01, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \leq 92$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kelima uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale > 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.53, dimana nilai tersebut  $>$

0.05. Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale > 92$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keenam uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale > 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.38, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale > 92$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketujuh uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale > 92$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.02, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale > 92$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedelapan uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale > 92$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.02, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale > 92$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Dari delapan percobaan menggunakan data parameter dengan  $scale 10$  dihasilkan empat parameter yang lolos uji signifikansi yaitu parameter *local scaling exponent* pada  $scale \leq 92$  berdasarkan *skewness*, *local scaling exponent* pada  $scale \leq 92$  berdasarkan *kurtosis*, *local scaling exponent* pada  $scale > 92$  berdasarkan *skewness*, dan *local scaling exponent* pada  $scale > 92$  berdasarkan *kurtosis*.

### 6.2.3. Uji Signifikansi Data dengan Scale 15

Setelah melakukan ekstraksi fitur menggunakan HOMDFA, parameter yang dihasilkan sebanyak 8 parameter. Parameter tersebut berasal dari rata-rata data pada  $scale < 119$  dan  $scale \geq 119$  pada fungsi fluktuasi dan *local scaling exponent*. Hasil uji signifikansi *Wilcoxon ranksum test* pada parameter data dengan scale 15 dapat dilihat pada Tabel 6.3.

Pada Tabel 6.3 terdapat kolom parameter yang berisikan setiap parameter hasil dari ekstraksi fitur menggunakan HOMDFA, pada kolom kedua terdapat nilai p-value dari hasil uji signifikansi menggunakan *Wilcoxon ranksum test*, sedangkan pada kolom ketiga terdapat keterangan dari hasil uji signifikansi yang menjelaskan apakah parameter terkait lolos uji signifikansi atau tidak.

**Tabel 6.3 Hasil Uji Signifikansi Parameter Scale 15**

Parameter	P-value	Keterangan
Rata-rata Fs Skewness pada $scale < 119$	0.06	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale < 119$	0.07	Tidak Signifikan
Rata-Rata Local Scaling Exponent Skewness pada $Scale < 119$	0.16	Tidak Signifikan
Rata-Rata Local Scaling Exponent Kurtosis pada $Scale < 119$	0.13	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Skewness $Scale \geq 119$	0.93	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale \geq 119$	0.69	Tidak Signifikan

Parameter	P-value	Keterangan
Rata-Rata Local Scaling Exponent Skewness <i>Scale</i> $\geq 119$	0.04	Signifikan
Rata-Rata Local Scaling Exponent Kurtosis <i>Scale</i> $\geq 119$	0.04	Signifikan

Percobaan pertama uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada *scale*  $< 119$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.06, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter rata-rata fungsi fluktuasi pada *scale*  $< 119$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedua uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada *scale*  $< 119$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.07, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi *scale*  $< 92$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketiga uji signifikansi, dilakukan pada parameter *local scaling exponent* pada *scale*  $< 119$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.16, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada *scale*  $< 119$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keempat uji signifikansi, dilakukan pada parameter *local scaling exponent* pada *scale*  $< 119$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.13, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada *scale*  $< 119$  berdasarkan *kurtosis* tidak

lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan kelima uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 119$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.93, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 119$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keenam uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 119$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.69, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 119$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketujuh uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 119$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.04, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 119$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedelapan uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 119$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.04, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 119$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Dari delapan percobaan menggunakan data parameter dengan  $scale 15$  dihasilkan dua parameter yang lolos uji signifikansi yaitu parameter *local scaling exponent* berdasarkan *skewness* pada  $scale \geq 119$  dan *local scaling exponent* berdasarkan *kurtosis* pada  $scale \geq 119$ .

#### 6.2.4. Uji Signifikansi Data dengan Scale 20

Setelah melakukan ekstraksi fitur menggunakan HOMDFA, parameter yang dihasilkan sebanyak 8 parameter. Parameter tersebut berasal dari rata-rata data pada  $scale \leq 111$  dan  $scale > 111$  pada fungsi fluktuasi dan *local scaling exponent*. Hasil uji signifikansi *Wilcoxon ranksum test* pada parameter data dengan scale 20 dapat dilihat pada Tabel 6.4.

Pada Tabel 6.4 terdapat kolom parameter yang berisikan setiap parameter hasil dari ekstraksi fitur menggunakan HOMDFA, pada kolom kedua terdapat nilai p-value dari hasil uji signifikansi menggunakan *Wilcoxon ranksum test*, sedangkan pada kolom ketiga terdapat keterangan dari hasil uji signifikansi yang menjelaskan apakah parameter terkait lolos uji signifikansi atau tidak.

**Tabel 6.4 Hasil Uji Signifikansi Parameter Scale 20**

Parameter	P-value	Keterangan
Rata-Rata Fungsi Fluktuasi Skewness pada $Scale \leq 111$	0.03	Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale \leq 111$	0.04	Signifikan
Rata-Rata Local Scaling Exponent Skewness pada $Scale \leq 111$	0.07	Tidak signifikan
Rata-Rata Local Scaling Exponent Kurtosis pada $Scale \leq 111$	0.04	Signifikan
Rata-Rata Fungsi Fluktuasi Skewness pada $Scale > 111$	0.69	Tidak signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis2 pada $Scale > 111$	0.45	Tidak signifikan

Rata-Rata Local Scaling Exponent Skewness pada $Scale > 111$	0.01	Signifikan
Rata-Rata Local Scaling Exponent Kurtosis pada $Scale > 111$	0.01	Signifikan

Percobaan pertama uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \leq 111$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.03, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \leq 111$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedua uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \leq 111$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.04, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \leq 111$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketiga uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \leq 111$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.07, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \leq 111$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keempat uji signifikansi, dilakukan pada parameter *local scaling exponent* berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.04, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \leq 111$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kelima uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale > 111$  berdasarkan *skewness*. Nilai

p-value yang dihasilkan sebesar 0.69, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale > 111$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keenam uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale > 111$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.45, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale > 111$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketujuh uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale > 111$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.01, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale > 111$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedelapan uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale > 111$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.014, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale > 111$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Dari delapan percobaan menggunakan data parameter dengan  $scale 10$  dihasilkan lima parameter yang lolos uji signifikansi yaitu parameter fungsi fluktuasi pada  $scale \leq 111$  berdasarkan *skewness*, fungsi fluktuasi pada  $scale \leq 111$  berdasarkan *kurtosis*, *local scaling exponent* pada  $scale \leq 111$  berdasarkan *kurtosis*, *local scaling exponent* pada  $scale > 111$  berdasarkan *skewness*, dan *local scaling exponent* pada  $scale > 111$  berdasarkan *kurtosis*.

### 6.2.5. Uji Signifikansi Data dengan Scale 25

Setelah melakukan ekstraksi fitur menggunakan HOMDFA, parameter yang dihasilkan sebanyak 8 parameter. Parameter tersebut berasal dari rata-rata data pada  $scale < 125$  dan  $scale \geq 125$  pada fungsi fluktuasi dan *local scaling exponent*. Hasil uji signifikansi *Wilcoxon ranksum test* pada parameter data dengan scale 25 dapat dilihat pada Tabel 6.5.

Pada Tabel 6.5 terdapat kolom parameter yang berisikan setiap parameter hasil dari ekstraksi fitur menggunakan HOMDFA, pada kolom kedua terdapat nilai p-value dari hasil uji signifikansi menggunakan *Wilcoxon ranksum test*, sedangkan pada kolom ketiga terdapat keterangan dari hasil uji signifikansi yang menjelaskan apakah parameter terkait lolos uji signifikansi atau tidak.

**Tabel 6.5 Hasil Uji Signifikansi Parameter Scale 25**

Parameter	P-value	Keterangan
Rata-rata Fungsi Fluktuasi Skewness pada $scale < 125$	0.02	Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale < 125$	0.01	Signifikan
Rata-Rata Local Scaling Exponent Skewness pada $Scale < 125$	0.08	Tidak Signifikan
Rata-Rata Local Scaling Exponent Kurtosis pada $Scale < 125$	0.05	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Skewness $Scale \geq 125$	0.69	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale \geq 125$	0.52	Tidak Signifikan

Parameter	P-value	Keterangan
Rata-Rata Local Scaling Exponent <i>Skewness Scale</i> $\geq 125$	0.03	Signifikan
Rata-Rata Local Scaling Exponent <i>Kurtosis Scale</i> $\geq 125$	0.02	Signifikan

Percobaan pertama uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale < 125$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.02, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale < 125$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedua uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale < 125$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.01, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \leq 125$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketiga uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale < 125$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.08 dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale < 125$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keempat uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale < 125$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.05, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale < 125$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan kelima uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 125$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.69, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 125$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keenam uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 125$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.52, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 125$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketujuh uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 125$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.03, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 125$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedelapan uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 125$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.02, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 125$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Dari delapan percobaan menggunakan data parameter dengan  $scale 25$  dihasilkan empat parameter yang lolos uji signifikansi yaitu parameter fungsi fluktuasi pada  $scale < 125$  berdasarkan *skewness*, fungsi fluktuasi pada  $scale < 125$  berdasarkan *kurtosis*, *local scaling exponent* pada  $scale \geq 125$  berdasarkan *skewness*, dan *local scaling exponent* pada  $scale \geq 125$  berdasarkan *kurtosis*.

### 6.2.6. Uji Signifikansi Data dengan Scale 30

Setelah melakukan ekstraksi fitur menggunakan HOMDFA, parameter yang dihasilkan sebanyak 8 parameter. Parameter tersebut berasal dari rata-rata data pada  $scale < 135$  dan  $scale \geq 135$  pada fungsi fluktuasi dan *local scaling exponent*. Hasil uji signifikansi *Wilcoxon ranksum test* pada parameter data dengan scale 30 dapat dilihat pada Tabel 6.6.

Pada Tabel 6.6 terdapat kolom parameter yang berisikan setiap parameter hasil dari ekstraksi fitur menggunakan HOMDFA, pada kolom kedua terdapat nilai p-value dari hasil uji signifikansi menggunakan *Wilcoxon ranksum test*, sedangkan pada kolom ketiga terdapat keterangan dari hasil uji signifikansi yang menjelaskan apakah parameter terkait lolos uji signifikansi atau tidak.

**Tabel 6.6 Hasil Uji Signifikansi Parameter Scale 30**

Parameter	P-value	Keterangan
Rata-rata Fs Skewness pada $scale < 135$	0.31	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale < 135$	0.37	Tidak Signifikan
Rata-Rata Local Scaling Exponent Skewness pada $Scale < 135$	0.09	Tidak Signifikan
Rata-Rata Local Scaling Exponent Kurtosis pada $Scale < 135$	0.04	Signifikan
Rata-Rata Fungsi Fluktuasi Skewness $Scale \geq 135$	0.26	Tidak Signifikan
Rata-Rata Fungsi Fluktuasi Kurtosis pada $Scale \geq 135$	0.13	Tidak Signifikan

Parameter	P-value	Keterangan
Rata-Rata Local Scaling Exponent Skewness <i>Scale</i> $\geq 135$	0.043	Signifikan
Rata-Rata Local Scaling Exponent Kurtosis <i>Scale</i> $\geq 135$	0.05	Tidak Signifikan

Percobaan pertama uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada *scale*  $< 135$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.31, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada *scale*  $< 135$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedua uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada *scale*  $< 135$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.37, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada *scale*  $\leq 135$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketiga uji signifikansi, dilakukan pada parameter *local scaling exponent* pada *scale*  $< 135$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.09 dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada *scale*  $< 135$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keempat uji signifikansi, dilakukan pada parameter *local scaling exponent* pada *scale*  $< 135$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.04, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada *scale*  $< 135$  berdasarkan *kurtosis* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kelima uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 135$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.26, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 135$  berdasarkan *skewness* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan keenam uji signifikansi, dilakukan pada parameter fungsi fluktuasi pada  $scale \geq 135$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.13, dimana nilai tersebut  $> 0.05$ . Dapat disimpulkan bahwa parameter fungsi fluktuasi pada  $scale \geq 135$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Percobaan ketujuh uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 135$  berdasarkan *skewness*. Nilai p-value yang dihasilkan sebesar 0.043, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 135$  berdasarkan *skewness* lolos uji signifikansi dan dapat digunakan sebagai input klasifikasi ANN.

Percobaan kedelapan uji signifikansi, dilakukan pada parameter *local scaling exponent* pada  $scale \geq 135$  berdasarkan *kurtosis*. Nilai p-value yang dihasilkan sebesar 0.05, dimana nilai tersebut  $< 0.05$ . Dapat disimpulkan bahwa parameter *local scaling exponent* pada  $scale \geq 135$  berdasarkan *kurtosis* tidak lolos uji signifikansi dan tidak dapat digunakan sebagai input klasifikasi ANN.

Dari delapan percobaan menggunakan data parameter dengan  $scale 25$  dihasilkan dua parameter yang lolos uji signifikansi yaitu parameter *local scaling exponent* pada  $scale < 135$  berdasarkan *kurtosis*, dan *local scaling exponent* pada  $scale \geq 135$  berdasarkan *skewness*.

### 6.3. Hasil Klasifikasi ANN

Data parameter hasil ekstraksi yang lolos uji signifikansi dijadikan input pada klasifikasi ANN. Klasifikasi dilakukan dengan menggunakan perbandingan data pelatihan dan pengujian sebesar 70 : 30. Uji coba klasifikasi dilakukan sebanyak 10 kali dengan dengan proses *trial error* pada jumlah *hidden node* antara 2-11. Percobaan klasifikasi akan dibagi menjadi dua bagian, yaitu klasifikasi ANN menggunakan parameter dengan *scale* 5, 10, 15, 20, 25, dan 30 yang lolos uji signifikansi.

#### 6.3.1. Hasil Klasifikasi ANN dengan Scale 5

Pada sub bab ini akan berisikan hasil klasifikasi ANN menggunakan parameter dengan *scale* 5. Berdasarkan hasil uji signifikan pada parameter tersebut, terdapat dua parameter yang lolos uji signifikansi, yaitu parameter *local scaling exponent* berdasarkan skewness pada *scale* < 92 dan *local scaling exponent* berdasarkan kurtosis pada *scale* < 92.

Klasifikasi ANN dilakukan dengan melakukan pelatihan terhadap model menggunakan data pelatihan sebanyak 144 data. Kemudian melakukan pengujian model menggunakan data pengujian sebanyak 62 data. Beberapa hasil klasifikasi *scale* 5 menggunakan data pengujian dapat dilihat pada Tabel 6.7. Pada Tabel 6.8 terdapat kolom prediksi yang menunjukkan hasil klasifikasinya, sedangkan kolom aktual menunjukkan label klasifikasi aktualnya.

**Tabel 6.7 Sebagian Hasil Klasifikasi Scale 10**

No	Aktual	Prediksi
1	Poor	Poor
2	Good	Poor
3	Poor	Good
4	Poor	Good

5	Good	Good
6	Good	Good
7	Good	Poor
...	...	...
62	Poor	Poor

### 6.3.2. Hasil Klasifikasi ANN dengan Scale 10

Pada sub bab ini akan berisikan hasil klasifikasi ANN menggunakan parameter dengan *scale* 10. Berdasarkan hasil uji signifikan pada parameter tersebut, terdapat empat parameter yang lolos uji signifikansi, yaitu parameter *local scaling exponent* pada *scale*  $\leq 92$  berdasarkan *skewness*, *local scaling exponent* pada *scale*  $\leq 92$  berdasarkan *kurtosis*, *local scaling exponent* pada *scale*  $> 92$  berdasarkan *skewness*, dan *local scaling exponent* pada *scale*  $> 92$  berdasarkan *kurtosis*.

Klasifikasi ANN dilakukan dengan melakukan pelatihan terhadap model menggunakan data pelatihan sebanyak 144 data. Kemudian melakukan pengujian model menggunakan data pengujian sebanyak 62 data. Beberapa hasil klasifikasi *scale* 10 menggunakan data pengujian dapat dilihat pada Tabel 6.8. Pada Tabel 6.8 terdapat kolom prediksi yang menunjukkan hasil klasifikasinya, sedangkan kolom aktual menunjukkan label klasifikasi aktualnya.

**Tabel 6.8 Sebagian Hasil Klasifikasi Scale 10**

No	Aktual	Prediksi
1	Poor	Poor
2	Good	Poor
3	Poor	Good
4	Poor	Good
5	Good	Good

6	Good	Poor
7	Good	Poor
...	...	...
62	Poor	Good

### 6.3.3. Hasil Klasifikasi ANN dengan Scale 15

Pada sub bab ini akan berisikan hasil klasifikasi ANN menggunakan parameter dengan *scale* 15. Berdasarkan hasil uji signifikan pada parameter tersebut, terdapat dua parameter yang lolos uji signifikansi, yaitu parameter *local scaling exponent* berdasarkan skewness pada *scale*  $\geq 119$  dan *local scaling exponent* berdasarkan kurtosis pada *scale*  $\geq 119$ .

Klasifikasi ANN dilakukan dengan melakukan pelatihan terhadap model menggunakan data pelatihan sebanyak 144 data. Kemudian melakukan pengujian model menggunakan data pengujian sebanyak 62 data. Beberapa hasil klasifikasi *scale* 15 menggunakan data pengujian dapat dilihat pada Tabel 6.9. Pada Tabel 6.9 terdapat kolom prediksi yang menunjukkan hasil klasifikasinya, sedangkan kolom aktual menunjukkan label klasifikasi aktualnya.

**Tabel 6.9 Sebagian Hasil Klasifikasi Scale 15**

No	Aktual	Prediksi
1	Poor	Good
2	Good	Good
3	Poor	Good
4	Poor	Good
5	Good	Good
6	Good	Good
7	Good	Good
...	...	...
62	Poor	Good

### 6.3.4. Hasil Klasifikasi ANN dengan Scale 20

Pada sub bab ini akan berisikan hasil klasifikasi ANN menggunakan parameter dengan *scale* 20. Berdasarkan hasil uji signifikan pada parameter tersebut, terdapat lima parameter yang lolos uji signifikansi, yaitu parameter fungsi fluktuasi pada *scale*  $\leq 111$  berdasarkan *skewness*, fungsi fluktuasi pada *scale*  $\leq 111$  berdasarkan *kurtosis*, *local scaling exponent* pada *scale*  $\leq 111$  berdasarkan *kurtosis*, *local scaling exponent* pada *scale*  $> 111$  berdasarkan *skewness*, dan *local scaling exponent* pada *scale*  $> 111$  berdasarkan *kurtosis*.

Klasifikasi ANN dilakukan dengan melakukan pelatihan terhadap model menggunakan data pelatihan sebanyak 144 data. Kemudian melakukan pengujian model menggunakan data pengujian sebanyak 62 data. Beberapa hasil klasifikasi *scale* 20 menggunakan data pengujian dapat dilihat pada Tabel 6.10. Pada Tabel 6.10 terdapat kolom prediksi yang menunjukkan hasil klasifikasinya, sedangkan kolom aktual menunjukkan label klasifikasi aktualnya.

**Tabel 6.10 Sebagian Hasil Klasifikasi Scale 20**

No	Aktual	Prediksi
1	Poor	Good
2	Good	Good
3	Poor	Good
4	Poor	Good
5	Good	Good
6	Good	Good
7	Good	Poor
...	...	...
62	Poor	Good

### 6.3.5. Hasil Klasifikasi ANN Scale 25

Pada sub bab ini akan berisikan hasil klasifikasi ANN menggunakan parameter dengan *scale* 25. Berdasarkan hasil uji signifikan pada parameter tersebut, terdapat empat parameter yang lolos uji signifikansi, yaitu parameter fungsi fluktuasi pada *scale* < 125 berdasarkan *skewness*, fungsi fluktuasi pada *scale* < 125 berdasarkan *kurtosis*, *local scaling exponent* pada *scale*  $\geq$  125 berdasarkan *skewness*, dan *local scaling exponent* pada *scale*  $\geq$  125 berdasarkan *kurtosis*.

Klasifikasi ANN dilakukan dengan melakukan pelatihan terhadap model menggunakan data pelatihan sebanyak 144 data. Kemudian melakukan pengujian model menggunakan data pengujian sebanyak 62 data. Beberapa hasil klasifikasi *scale* 25 menggunakan data pengujian dapat dilihat pada Tabel 6.11. Pada Tabel 6.11 terdapat kolom prediksi yang menunjukkan hasil klasifikasinya, sedangkan kolom aktual menunjukkan label klasifikasi aktualnya.

**Tabel 6.11 Sebagian Hasil Klasifikasi Scale 25**

No	Aktual	Prediksi
1	Poor	Good
2	Good	Good
3	Poor	Good
4	Poor	Good
5	Good	Good
6	Good	Good
7	Good	Poor
...	...	...
62	Poor	Poor

### 6.3.6. Hasil Klasifikasi ANN Scale 30

Pada sub bab ini akan berisikan hasil klasifikasi ANN menggunakan parameter dengan *scale* 30. Berdasarkan hasil uji signifikan pada parameter tersebut, terdapat dua parameter yang lolos uji signifikansi, yaitu parameter *local scaling exponent* pada *scale* < 135 berdasarkan *kurtosis* dan *local scaling exponent* pada *scale* >= 135 berdasarkan *skewness*.

Klasifikasi ANN dilakukan dengan melakukan pelatihan terhadap model menggunakan data pelatihan sebanyak 144 data. Kemudian melakukan pengujian model menggunakan data pengujian sebanyak 62 data. Beberapa hasil klasifikasi *scale* 30 menggunakan data pengujian dapat dilihat pada Tabel 6.12. Pada Tabel 6.12 terdapat kolom prediksi yang menunjukkan hasil klasifikasinya, sedangkan kolom aktual menunjukkan label klasifikasi aktualnya.

**Tabel 6.12 Sebagian Hasil Klasifikasi Scale 30**

No	Aktual	Prediksi
1	Good	Good
2	Good	Good
3	Good	Good
4	Good	Good
5	Good	Good
6	Poor	Good
7	Good	Poor
...	...	...
62	Good	Good

## 6.4. Hasil Uji Performa

Setelah melakukan percobaan pada klasifikasi ANN dan menghasilkan beberapa model ANN. Kemudian dilakukan

analisis terhadap hasil uji performa menggunakan *confusion matrix* dan ROC untuk menentukan model terbaik.

*Confusion matrix* menunjukkan ringkasan jumlah data yang dapat diklasifikasikan secara benar dan salah. Dari hasil *confusion matrix* dapat diketahui nilai *accuracy*, *sensitivity*, dan *specificity* untuk mengukur performa setiap model. Nilai *accuracy* menunjukkan prosentase data diklasifikasikan dengan benar. Nilai *sensitivity* menunjukkan rasio dari data aktual positif yang dapat diklasifikasikan dengan benar. Nilai *specificity* menunjukkan rasio dari data aktual negatif yang dapat diklasifikasikan dengan benar.

Sedangkan, Performa setiap model juga akan dievaluasi dengan ROC dengan melakukan pengukuran pada luas daerah di bawah grafik ROC (AUC). Nilai AUC dapat menunjukkan tingkat performa suatu model. Semakin besar nilai AUC, menunjukkan semakin baiknya performa model. Apabila terdapat model yang memiliki nilai *accuracy* yang sama, maka model terbaik akan ditentukan berdasarkan nilai AUC tertinggi dari model tersebut.

#### 6.4.1. Hasil Uji Performa Klasifikasi ANN dengan Scale 5

Pada sub bab ini berisikan hasil dan analisis uji performa menggunakan *confusion matrix* dan ROC untuk setiap percobaan pada data dengan *scale 5*. Nilai dari *confusion matrix* untuk setiap model dapat dilihat pada Tabel 6.13 hingga Tabel 6.22.

**Tabel 6.13 Confusion Matrix dengan Hidden Node 2 pada Data Scale 5**

<i>Hidden Node 2</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	27	5
	Buruk	18	12

Tabel 6.13 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 2. Dari Tabel 6.13, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 2 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 27, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 12, data prognosis baik yang diklasifikasikan dengan salah sejumlah 18, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 5.

**Tabel 6.14 Confusion Matrix dengan Hidden Node 3 pada Data Scale 5**

<i>Hidden Node 3</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	27	6
	Buruk	18	11

Tabel 6.14 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 3. Dari Tabel 6.14, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 3 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 27, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 18, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.15 Confusion Matrix dengan Hidden Node 4 pada Data Scale 5**

<i>Hidden Node 4</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	27	6
	Buruk	18	11

Tabel 6.15 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 4. Dari Tabel 6.15, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 4 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 27, data prognosis buruk yang

diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 18, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.16 Confusion Matrix dengan Hidden Node 5 pada Data Scale 5**

<i>Hidden Node 5</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	27	6
	Buruk	18	11

Tabel 6.16 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 5. Dari Tabel 6.16, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 5 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 27, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 18, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.17 Confusion Matrix dengan Hidden Node 6 pada Data Scale 5**

<i>Hidden Node 6</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	28	6
	Buruk	17	11

Tabel 6.17 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 6. Dari Tabel 6.17, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 6 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.18 Confusion Matrix dengan Hidden Node 7 pada Data Scale 5**

<i>Hidden Node 7</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	27	6
	Buruk	18	11

Tabel 6.18 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 7. Dari Tabel 6.18, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 7 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 27, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 18, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.19 Confusion Matrix dengan Hidden Node 8 pada Data Scale 5**

<i>Hidden Node 8</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	28	6
	Buruk	17	11

Tabel 6.19 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 8. Dari Tabel 6.19, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 8 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.20 Confusion Matrix dengan Hidden Node 9 pada Data Scale 5**

<i>Hidden Node 9</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	28	6
	Buruk	17	11

Tabel 6.20 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 9. Dari Tabel 6.20, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 9 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.21 Confusion Matrix dengan Hidden Node 10 pada Data Scale 5**

<i>Hidden Node 10</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.21 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 10. Dari Tabel 6.21, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.22 Confusion Matrix dengan Hidden Node 11 pada Data Scale 5**

<i>Hidden Node 11</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	16
	Buruk	0	1

Tabel 6.22 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 11. Dari Tabel 6.22, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 11 menghasilkan data prognosis baik yang

diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 1, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 16.

**Tabel 6.23 Hasil Uji Performa Klasifikasi ANN Scale 5 Epoch 3000**

Jumlah Hidden Node	Accuracy	Sensitifity	Specificity	AUC
2	62.90%	0.629	0.677	0.68
3	61.29%	0.613	0.634	0.692
4	61.29%	0.613	0.634	0.689
5	61.29%	0.613	0.634	0.69
6	62.90%	0.629	0.64	0.681
7	61.29%	0.613	0.634	0.689
8	62.90%	0.629	0.64	0.688
9	62.90%	0.629	0.64	0.682
10	72.58%	0.726	0.274	0.651
11	74.19%	0.742	0.317	0.651

Hasil uji performa untuk setiap parameter dapat dilihat pada Tabel 6.23. Berdasarkan Tabel 6.23, nilai *accuracy* tertinggi sebesar 74.19% terdapat pada model dengan parameter *hidden node* berjumlah 11, tapi jika dilihat pada tabel *confusion matrix* model tersebut pada Tabel 6.22, didapatkan jika tidak adanya kelas prognosis buruk yang dapat diklasifikasikan dengan benar. Oleh karena itu, model dengan jumlah *hidden node* 1 tidak dapat dipilih menjadi model terbaik.

Berdasarkan urutan hasil *accuracy* tertinggi kedua, yaitu sebesar 72.58% dengan parameter jumlah *hidden node* 10, model tersebut juga tidak dapat dipilih menjadi model terbaik dikarenakan model hanya dapat mengklasifikasikan 1 data

prognosis buruk dengan benar. Sedangkan, pada kelas prognosis baik dapat diklasifikasikan seluruhnya dengan benar.

Kemudian jika dilakukan pengamatan terhadap hasil *accuracy* tertinggi ketiga, yaitu sebesar 62.90%, terdapat 4 model yang memiliki *parameter* berbeda dengan hasil *accuracy* yang sama. Model tersebut antara lain model dengan *hidden node* berjumlah 2, 6, 8, dan 9. Dikarenakan menghasilkan nilai *accuracy* yang sama, penentuan model terbaik akan didasarkan pada nilai AUC. Berdasarkan nilai AUC tertinggi sebesar 0.688 dari keempat model tersebut, model terbaik merupakan model dengan jumlah *hidden node* 8. Sehingga dapat disimpulkan jika model terbaik dari data dengan *scale* 5 merupakan model dengan jumlah *hidden node* 8 yang menghasilkan nilai *accuracy* sebesar 62.90%, *sensitivity* 0.629, *specificity* 0.64, dan AUC 0.688.

#### 6.4.2. Hasil Uji Performa Klasifikasi ANN dengan Scale 10

Pada sub bab ini berisikan hasil dan analisis uji performa menggunakan *confusion matrix* dan ROC untuk setiap percobaan pada data dengan *scale* 10. Nilai dari *confusion matrix* untuk setiap model dapat dilihat pada Tabel 6.24 hingga Tabel 6.33.

**Tabel 6.24 Confusion Matrix dengan Hidden Node 2 pada Data Scale 10**

<i>Hidden Node 2</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	14
	Buruk	12	3

Tabel 6.24 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 2. Dari Tabel 6.24, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 2 menghasilkan data prognosis baik yang diklasifikasikan

dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 3, data prognosis baik yang diklasifikasikan dengan salah sejumlah 12, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 14.

**Tabel 6.25 Confusion Matrix dengan Hidden Node 3 pada Data Scale 10**

<i>Hidden Node 3</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	35	15
	Buruk	10	2

Tabel 6.25 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 3. Dari Tabel 6.25, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 3 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 35, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 2, data prognosis baik yang diklasifikasikan dengan salah sejumlah 10, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 15.

**Tabel 6.26 Confusion Matrix dengan Hidden Node 4 pada Data Scale 10**

<i>Hidden Node 4</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	34	13
	Buruk	11	4

Tabel 6.26 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 4. Dari Tabel 6.26, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 4 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 34, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 11, dan data

prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.27 Confusion Matrix dengan Hidden Node 5 pada Data Scale 10**

<i>Hidden Node 5</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	13
	Buruk	12	4

Tabel 6.27 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 5. Dari Tabel 6.27, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 5 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 12, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.28 Confusion Matrix dengan Hidden Node 6 pada Data Scale 10**

<i>Hidden Node 6</i>		<i>Actual Class</i>	
		Baik	Buruk
Predicted Class	Baik	28	9
	Buruk	17	8

Tabel 6.28 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 6. Dari Tabel 6.28, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 6 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 8, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 9.

**Tabel 6.29 Confusion Matrix dengan Hidden Node 7 pada Data Scale 10**

<i>Hidden Node 7</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	28	9
	Buruk	17	8

Tabel 6.29 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node*. Dari Tabel 6.29, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node 7* menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 8, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 9.

**Tabel 6.30 *Confusion Matrix* dengan *Hidden Node 8* pada *Data Scale 10***

<i>Hidden Node 8</i>		<i>Actual Class</i>	
		<i>Baik</i>	<i>Buruk</i>
<i>Predicted Class</i>	<i>Baik</i>	30	8
	<i>Buruk</i>	15	9

Tabel 6.30 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node 8*. Dari Tabel 6.30, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node 8* menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 30, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 9, data prognosis baik yang diklasifikasikan dengan salah sejumlah 15, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 8.

**Tabel 6.31 *Confusion Matrix* dengan *Hidden Node 9* pada *Data Scale 10***

<i>Hidden Node 9</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	30	8
	Buruk	15	9

Tabel 6.31 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 9. Dari Tabel 6.31, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 9 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 30, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 9, data prognosis baik yang diklasifikasikan dengan salah sejumlah 15, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 8.

**Tabel 6.32 Confusion Matrix dengan Hidden Node 10 pada Data Scale 10**

<i>Hidden Node 10</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	32	10
	Buruk	13	7

Tabel 6.32 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 10. Dari Tabel 6.32, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 32, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 13, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 10.

**Tabel 6.33 Confusion Matrix dengan Hidden Node 11 pada Data Scale 10**

<i>Hidden Node 11</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	32	10
	Buruk	13	7

Tabel 6.33 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 11. Dari Tabel 6.33, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden*

*node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 32, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 13, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 10.

**Tabel 6.34 Hasil Uji Performa Klasifikasi ANN Scale 10 Epoch 3000**

Jumlah Hidden Node	Accuracy	Sensitivity	Specificity	AUC
2	58.06%	0.581	0.329	0.467
3	59.68%	0.597	0.299	0.49
4	61.29%	0.613	0.378	0.562
5	59.68%	0.597	0.372	0.476
6	58.06%	0.581	0.512	0.616
7	59.68%	0.597	0.555	0.609
8	62.90%	0.629	0.567	0.593
9	62.90%	0.629	0.567	0.635
10	62.90%	0.629	0.494	0.579
11	64.52%	0.645	0.5	0.573

Dari hasil uji performa menggunakan *confusion matrix* dan AUC, dihasilkan nilai performa untuk masing-masing model yang dapat dilihat pada Tabel 6.34. Berdasarkan Tabel 6.34, performa model terbaik yang dihasilkan dengan menggunakan data *scale* 10 merupakan model dengan jumlah *hidden node* 11, dimana menghasilkan nilai *accuracy* tertinggi sebesar 64.29%, *sensitifity* sebesar 0.645 dan *specificity* sebesar 0.5. Sedangkan nilai AUC yang dihasilkan juga memiliki *range* nilai yang tidak terlalu jauh, yaitu sebesar 0.573.

### 6.4.3. Hasil Uji Performa Klasifikasi ANN dengan Scale 15

Pada sub bab ini berisikan hasil dan analisis uji performa menggunakan *confusion matrix* dan ROC untuk setiap percobaan pada data dengan *scale* 10. Nilai dari *confusion matrix* untuk setiap model dapat dilihat pada Tabel 6.35 hingga Tabel 6.44.

**Tabel 6.35 Confusion Matrix dengan Hidden Node 2 pada Data Scale 15**

<i>Hidden Node 2</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.35 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 2. Dari Tabel 6.35, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 2 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.36 Confusion Matrix dengan Hidden Node 3 pada Data Scale 15**

<i>Hidden Node 3</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.36 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 3. Dari Tabel 6.36, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 3 menghasilkan data prognosis baik yang diklasifikasikan

dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.37 Confusion Matrix dengan Hidden Node 4 pada Data Scale 15**

<i>Hidden Node 4</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.37 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 4. Dari Tabel 6.37, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 4 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.38 Confusion Matrix dengan Hidden Node 5 pada Data Scale 15**

<i>Hidden Node 5</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.38 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 5. Dari Tabel 6.38, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 5 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data

prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.39 Confusion Matrix dengan Hidden Node 6 pada Data Scale 15**

<i>Hidden Node 6</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.39 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 6. Dari Tabel 6.39, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 6 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.40 Confusion Matrix dengan Hidden Node 7 pada Data Scale 15**

<i>Hidden Node 7</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.40 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 7. Dari Tabel 6.40, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 7 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.41 Confusion Matrix dengan Hidden Node 8 pada Data Scale 15**

<i>Hidden Node 8</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.41 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 8. Dari Tabel 6.41, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 8 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.42 Confusion Matrix dengan Hidden Node 9 pada Data Scale 15**

<i>Hidden Node 9</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.42 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 9. Dari Tabel 6.42, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 9 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.43 Confusion Matrix dengan Hidden Node 10 pada Data Scale 15**

<i>Hidden Node 10</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.43 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 10. Dari Tabel 6.43, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.44 Confusion Matrix dengan Hidden Node 11 pada Data Scale 15**

<i>Hidden Node 11</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.44 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 11. Dari Tabel 6.44, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 11 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.45 Hasil Uji Performa Klasifikasi ANN Scale 15 Epoch 3000**

Jumlah Hidden Node	Accuracy	Sensitifity	Specificity	AUC
2	72.58%	0.726	0.274	0.467
3	72.58%	0.527	0.274	0.467
4	72.58%	0.527	0.274	0.467
5	72.58%	0.726	0.274	0.472
6	72.58%	0.726	0.274	0.472
7	72.58%	0.726	0.274	0.472
8	72.58%	0.726	0.274	0.472
9	72.58%	0.726	0.274	0.471
10	72.58%	0.726	0.274	0.471
11	72.58%	0.726	0.274	0.471

Hasil uji performa untuk setiap parameter dapat dilihat pada Tabel 6.45. Berdasarkan Tabel 6.45, dapat dilihat jika setiap parameter *hidden* 2-11 menghasilkan nilai *accuracy* yang sama. Apabila dilakukan pengamatan pada tabel *confusion matrix* pada Tabel 6.35 hingga Tabel 6.44, model sama sekali tidak dapat melakukan klasifikasi dengan benar pada kelas prognosis buruk, sedangkan pada kelas prognosis baik, model dapat mengklasifikasikan setiap data dengan benar. Adanya kecenderungan *overfitting* pada suatu kelas tersebut, menyebabkan hasil klasifikasikan yang dihasilkan tidak baik. Oleh karena itu tidak adanya model yang dipilih pada data dengan *scale* 15.

#### **6.4.4. Hasil Uji Performa Klasifikasi ANN dengan Scale 20**

Pada sub bab ini berisikan hasil dan analisis uji performa pada nilai *confusion matrix* dan ROC untuk setiap percobaannya. Analisis dilakukan untuk menentukan model terbaik

berdasarkan hasil percobaan pada data *scale* 20. Nilai dari *confusion matrix* untuk setiap model dapat dilihat pada Tabel 6.46 hingga Tabel 6.55.

**Tabel 6.46 Confusion Matrix dengan Hidden Node 2 pada Data Scale 20**

<i>Hidden Node 2</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	31	13
	Buruk	14	4

Tabel 6.46 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 2. Dari Tabel 6.46, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 2 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 31, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 14, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.47 Confusion Matrix dengan Hidden Node 3 pada Data Scale 20**

<i>Hidden Node 3</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	30	13
	Buruk	15	4

Tabel 6.47 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 3. Dari Tabel 6.47, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 3 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 30, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 15, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.48 Confusion Matrix dengan Hidden Node 4 pada Data Scale 20**

<i>Hidden Node 4</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	22	10
	Buruk	23	7

Tabel 6.48 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 4. Dari Tabel 6.48, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 4 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 22, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 23, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 10.

**Tabel 6.49 Confusion Matrix dengan Hidden Node 5 pada Data Scale 20**

<i>Hidden Node 5</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	28	12
	Buruk	17	5

Tabel 6.49 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 5. Dari Tabel 6.49, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 5 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 5, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 12.

**Tabel 6.50 Confusion Matrix dengan Hidden Node 6 pada Data Scale 20**

<i>Hidden Node 6</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	22	6
	Buruk	23	11

Tabel 6.50 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 6. Dari Tabel 6.50, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 6 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 22, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 11, data prognosis baik yang diklasifikasikan dengan salah sejumlah 23, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.51 Confusion Matrix dengan Hidden Node 7 pada Data Scale 20**

<i>Hidden Node 7</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	32	11
	Buruk	13	16

Tabel 6.51 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 7. Dari Tabel 6.51, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 7 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 32, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 16, data prognosis baik yang diklasifikasikan dengan salah sejumlah 13, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 11.

**Tabel 6.52 Confusion Matrix dengan Hidden Node 8 pada Data Scale 20**

<i>Hidden Node 8</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	32	13
	Buruk	12	14

Tabel 6.52 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 8. Dari Tabel 6.52, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 8 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 32, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 14, data prognosis baik yang diklasifikasikan dengan salah sejumlah 12, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.53 Confusion Matrix dengan Hidden Node 9 pada Data Scale 20**

<i>Hidden Node 9</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	28	12
	Buruk	17	5

Tabel 6.53 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 9. Dari Tabel 6.53, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 9 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 5, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 12.

**Tabel 6.54 Confusion Matrix dengan Hidden Node 10 pada Data Scale 20**

<i>Hidden Node 10</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	13
	Buruk	12	4

Tabel 6.54 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 10. Dari Tabel 6.54, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 12, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.55 Confusion Matrix dengan Hidden Node 11 pada Data Scale 20**

<i>Hidden Node 11</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	13
	Buruk	12	4

Tabel 6.55 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 11. Dari Tabel 6.55, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 11 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 12, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.56 Hasil Uji Performa Klasifikasi ANN Scale 20 Epoch 3000**

Jumlah Hidden Node	Accuracy	Sensitivity	Specificity	AUC
2	56.45%	0.565	0.498	0.498
3	54.84%	0.548	0.447	0.447
4	46.77%	0.468	0.473	0.473
5	53.23%	0.532	0.461	0.461
6	53.23%	0.532	0.591	0.591
7	61.29%	0.613	0.533	0.533
8	59.68%	0.597	0.527	0.527
9	53.23%	0.532	0.48	0.48
10	59.68%	0.597	0.485	0.485
11	58.06%	0.581	0.486	0.486

Dari hasil uji performa menggunakan *confusion matrix* dan AUC, dihasilkan nilai performa untuk masing-masing model yang dapat dilihat pada Tabel 6.56. Berdasarkan Tabel 6.56, performa model terbaik yang dihasilkan dengan menggunakan data *scale 20* merupakan model dengan jumlah *hidden node* 7, dimana menghasilkan nilai *accuracy* tertinggi sebesar 61.29%, *sensitivity* sebesar 0.613 dan *specificity* sebesar 0.533. Sedangkan nilai AUC yang dihasilkan juga memiliki *range* nilai yang tidak terlalu jauh, yaitu sebesar 0.533.

#### **6.4.5. Hasil Uji Performa Klasifikasi ANN dengan Scale 25**

Pada sub bab ini berisikan hasil dan analisis uji performa menggunakan *confusion matrix* dan ROC untuk setiap percobaan pada data dengan *scale 10*. Nilai dari *confusion matrix* untuk setiap model dapat dilihat pada Tabel 6.57 hingga Tabel 6.66.

**Tabel 6.57 Confusion Matrix dengan Hidden Node 2 pada Data Scale 25**

<i>Hidden Node 2</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	31	10
	Buruk	14	7

Tabel 6.57 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node 2*. Dari Tabel 6.57, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node 2* menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 31, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 14, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 10.

**Tabel 6.58 Confusion Matrix dengan Hidden Node 3 pada Data Scale 25**

<i>Hidden Node 3</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	31	10
	Buruk	14	7

Tabel 6.58 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node 3*. Dari Tabel 6.58, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node 3* menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 31, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 14, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 10.

**Tabel 6.59 Confusion Matrix dengan Hidden Node 4 pada Data Scale 25**

<i>Hidden Node 4</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	45	17
	Buruk	0	0

Tabel 6.58 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 4. Dari Tabel 6.58, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 4 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 45, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 0, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.60 Confusion Matrix dengan Hidden Node 5 pada Data Scale 25**

<i>Hidden Node 5</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	43	17
	Buruk	2	0

Tabel 6.60 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 5. Dari Tabel 6.60, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 5 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 43, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 0, data prognosis baik yang diklasifikasikan dengan salah sejumlah 2, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.61 Confusion Matrix dengan Hidden Node 6 pada Data Scale 25**

<i>Hidden Node 6</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	35	13
	Buruk	10	4

Tabel 6.61 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 6. Dari Tabel 6.61, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 6 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 35, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 10, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.62 Confusion Matrix dengan Hidden Node 7 pada Data Scale 25**

<i>Hidden Node 7</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	35	13
	Buruk	10	4

Tabel 6.61 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 7. Dari Tabel 6.61, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 7 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 35, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 10, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 13.

**Tabel 6.63 Confusion Matrix dengan Hidden Node 8 pada Data Scale 25**

<i>Hidden Node 8</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	42	14
	Buruk	3	3

Tabel 6.62 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 8. Dari Tabel 6.62, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 8 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 42, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 3, data prognosis baik yang diklasifikasikan dengan salah sejumlah 3, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 14.

**Tabel 6.64 Confusion Matrix dengan Hidden Node 9 pada Data Scale 25**

<i>Hidden Node 9</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	28	10
	Buruk	17	7

Tabel 6.64 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 9. Dari Tabel 6.64, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 9 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 28, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 10.

**Tabel 6.65 Confusion Matrix dengan Hidden Node 2 pada Data Scale 25**

<i>Hidden Node 10</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	31	10
	Buruk	14	7

Tabel 6.65 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 10. Dari Tabel 6.65, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 31, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 14, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 10.

**Tabel 6.66 Confusion Matrix dengan Hidden Node 11 pada Data Scale 25**

<i>Hidden Node 11</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	27	8
	Buruk	18	9

Tabel 6.66 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 11. Dari Tabel 6.66, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 27, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 9, data prognosis baik yang diklasifikasikan dengan salah sejumlah 18, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 8.

**Tabel 6.67 Hasil Uji Performa Klasifikasi ANN Scale 25 Epoch 3000**

Jumlah Hidden Node	Accuracy	Sensitifity	Specificity	ROC
2	61.29%	0.613	0.488	0.544
3	61.29%	0.613	0.488	0.544
4	72.58%	0.726	0.274	0.532
5	69.35%	0.694	0.262	0.532
6	62.90%	0.629	0.384	0.544
7	62.90%	0.629	0.384	0.544
8	72.58%	0.726	0.384	0.531
9	56.45%	0.565	0.469	0.584
10	61.29%	0.613	0.488	0.545
11	58.06%	0.581	0.549	0.588

Hasil uji performa untuk setiap parameter pada data dengan *scale* 25 dapat dilihat pada Tabel 6.67. Berdasarkan Tabel 6.67, performa model terbaik yang dihasilkan dengan menggunakan data *scale* 20 merupakan model dengan jumlah *hidden node* 8, dimana menghasilkan nilai *accuracy* tertinggi sebesar 72.58%, *sensitifity* sebesar 0.726, *specificity* sebesar 0.384, dan AUC sebesar 0.544.

#### **6.4.6. Hasil Uji Performa Klasifikasi ANN dengan Scale 30**

Pada sub bab ini berisikan hasil dan analisis uji performa menggunakan *confusion matrix* dan ROC untuk setiap percobaan pada data dengan *scale* 10. Nilai dari *confusion matrix* untuk setiap model dapat dilihat pada Tabel 6.68 hingga Tabel 6.77.

**Tabel 6.68 Confusion Matrix dengan Hidden Node 2 pada Data Scale 30**

<i>Hidden Node 2</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	17
	Buruk	6	5

Tabel 6.68 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 2. Dari Tabel 6.68, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 2 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 5, data prognosis baik yang diklasifikasikan dengan salah sejumlah 6, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.69 Confusion Matrix dengan Hidden Node 3 pada Data Scale 30**

<i>Hidden Node 3</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	17
	Buruk	6	5

Tabel 6.69 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 3. Dari Tabel 6.69, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 3 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 5, data prognosis baik yang diklasifikasikan dengan salah sejumlah 6, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.70 Confusion Matrix dengan Hidden Node 4 pada Data Scale 30**

<i>Hidden Node 4</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	17
	Buruk	6	5

Tabel 6.70 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 4. Dari Tabel 6.70, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 4 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 5, data prognosis baik yang diklasifikasikan dengan salah sejumlah 17, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 6.

**Tabel 6.71 Confusion Matrix dengan Hidden Node 5 pada Data Scale 30**

<i>Hidden Node 5</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	17
	Buruk	6	5

Tabel 6.71 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 5. Dari Tabel 6.71, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 5 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 5, data prognosis baik yang diklasifikasikan dengan salah sejumlah 6, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.72 Confusion Matrix dengan Hidden Node 6 pada Data Scale 30**

<i>Hidden Node 6</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	31	17
	Buruk	8	5

Tabel 6.72 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 6. Dari Tabel 6.72, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 6 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 31, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 5, data prognosis baik yang diklasifikasikan dengan salah sejumlah 8, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 17.

**Tabel 6.73 Confusion Matrix dengan Hidden Node 7 pada Data Scale 30**

<i>Hidden Node 7</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	31	15
	Buruk	8	7

Tabel 6.73 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 7. Dari Tabel 6.73, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 7 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 31, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 7, data prognosis baik yang diklasifikasikan dengan salah sejumlah 8, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 15.

**Tabel 6.74 Confusion Matrix dengan Hidden Node 8 pada Data Scale 30**

<i>Hidden Node 8</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	16
	Buruk	6	6

Tabel 6.74 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 8. Dari Tabel 6.74, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 8 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 6, data prognosis baik yang diklasifikasikan dengan salah sejumlah 6, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 16.

**Tabel 6.75 Confusion Matrix dengan Hidden Node 9 pada Data Scale 30**

<i>Hidden Node 9</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	32	16
	Buruk	7	6

Tabel 6.75 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 9. Dari Tabel 6.75, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 9 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 32, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 6, data prognosis baik yang diklasifikasikan dengan salah sejumlah 7, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 16.

**Tabel 6.76 Confusion Matrix dengan Hidden Node 10 pada Data Scale 30**

<i>Hidden Node 10</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	32	16
	Buruk	7	6

Tabel 6.76 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 10. Dari Tabel 6.76, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 10 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 32, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 6, data prognosis baik yang diklasifikasikan dengan salah sejumlah 7, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 16.

**Tabel 6.77 Confusion Matrix dengan Hidden Node 11 pada Data Scale 30**

<i>Hidden Node 11</i>		<i>Actual Class</i>	
		Baik	Buruk
<i>Predicted Class</i>	Baik	33	18
	Buruk	6	4

Tabel 6.77 merupakan tabel *confusion matrix* pada model dengan jumlah *hidden node* 11. Dari Tabel 6.77, dapat diketahui hasil klasifikasi menggunakan model dengan jumlah *hidden node* 11 menghasilkan data prognosis baik yang diklasifikasikan dengan benar sejumlah 33, data prognosis buruk yang diklasifikasikan dengan benar sejumlah 4, data prognosis baik yang diklasifikasikan dengan salah sejumlah 6, dan data prognosis buruk yang diklasifikasikan dengan salah sejumlah 18.

**Tabel 6.78 Hasil Uji Performa Klasifikasi ANN Scale 30 Epoch 3000**

Jumlah Hidden Node	Accuracy	Sensitifity	Specificity	AUC
2	62.30%	0.623	0.45	0.562
3	62.30%	0.623	0.45	0.545
4	62.30%	0.623	0.45	0.566
5	62.30%	0.623	0.45	0.568
6	59.02%	0.59	0.432	0.579
7	62.30%	0.623	0.49	0.531
8	63.93%	0.639	0.48	0.568
9	62.30%	0.623	0.47	0.578
10	62.30%	0.623	0.47	0.579
11	60.66%	0.607	0.421	0.555

Hasil uji performa untuk setiap parameter pada data dengan *scale* 30 dapat dilihat pada Tabel 6.78. Berdasarkan Tabel 6.78, performa model terbaik yang dihasilkan dengan menggunakan data *scale* 30 merupakan model dengan jumlah *hidden node* 8, dimana menghasilkan nilai *accuracy* tertinggi sebesar 63.93%, *sensitifity* sebesar 0.639, *specificity* sebesar 0.48, dan AUC sebesar 0.544.

## 6.5. Kesimpulan Percobaan

Dari percobaan klasifikasi ANN yang dilakukan, dihasilkan masing-masing satu model untuk setiap *scale*. Pada tahapan ini akan dilakukan pemilihan model terbaik dengan membandingkan hasil uji performa pada kedua model tersebut. Hasil uji performa pada model terbaik untuk masing-masing *scale* dapat dilihat pada Tabel 6.79. Dari hasil uji performa pada Tabel 6.79.

**Tabel 6.79 Model Terbaik setiap Scale**

<i>Scale</i>	<i>Hidden Node</i>	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>	<i>AUC</i>
5	8	62.90%	0.629	0.64	0.688
10	11	64.52%	0.645	0.5	0.573
20	7	61.29%	0.613	0.533	0.533
25	8	72.58%	0.726	0.384	0.531
30	8	63.93%	0.639	0.48	0.568

Dari hasil masing-masing model terbaik untuk setiap *scale*, selanjutnya akan dilakukan uji coba lebih lanjut untuk mengetahui apakah dapat diperoleh model dengan nilai *accuracy* yang lebih tinggi menggunakan parameter yang berbeda. Rancangan parameter yang digunakan pada uji coba klasifikasi ANN dapat dilihat pada Tabel 6.35.

**Tabel 6.80 Rancangan Parameter Uji Klasifikasi Lanjutan**

<b>Parameter</b>	<b>Nilai</b>	<b>Deskripsi</b>
Input Node	Scale 5 = 2 Scale 10 = 4 Scale 20 = 5 Scale 25 = 4 Scale 30 = 2	Berdasarkan jumlah parameter yang lolos uji signifikansi untuk setiap <i>scale</i> -nya
Hidden Node	Scale 5 = 8 Scale 10 = 11 Scale 20 = 7 Scale 25 = 8 Scale 30 = 8	Berdasarkan model terbaik pada uji coba sebelumnya pada Tabel 6.79.
Output Node	1	Prognosis baik atau buruk
Learning Rate	0.1-0.9	<i>Trial Error</i>
Momentum	0.1-0.9	<i>Trial Error</i>
Epoch	2000	<i>Fix</i>

Parameter *hidden node* dari percobaan lanjutan akan menggunakan nilai *hidden node* dari model terbaik untuk setiap *scale*-nya dari percobaan sebelumnya. Nilai parameter *hidden node* untuk setiap *scale* didasarkan pada Tabel 6.79. Sedangkan untuk nilai *learning rate* dan *momentum* didasarkan pada penelitian sebelumnya dengan topik sejenis yang menggunakan nilai *learning rate* antara 0.5-0.9 dan *momentum* antara 0.1-0,9 [8]. Tetapi pada penelitian ini akan digunakan *range* nilai *learning rate* yang lebih besar yaitu antara 0,1-0.9 yang disesuaikan pula dengan Batasan nilai *learning rate* yaitu antara 0-1. Sedangkan untuk nilai epoch didasarkan pada percobaan yang telah dilakukan LAMPIRAN , adanya kemungkinan kenaikan nilai *accuracy* yang dihasilkan jika menggunakan epoch 2000. Oleh karena itu, pada percobaan lanjutan ini digunakan *epoch* 2000.

Berdasarkan dari hasil percobaan lanjutan yang dilakukan, dihasilkan model terbaik untuk masing *scale*. Model terbaik untuk setiap *scale* dapat dilihat pada Tabel 6.81. Hasil untuk masing-masing percobaan dapat dilihat pada LAMPIRAN hingga LAMPIRAN .

**Tabel 6.81 Model Terbaik Uji Coba Lanjutan Klasifikasi ANN**

<i>Scale</i>	<i>Hidden Node</i>	<i>Leaning Rate</i>	<i>Momentum</i>	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>	<i>AUC</i>
5	8	0,1	0,2	74.19%	0.742	0.39	0.681
			0,3	74.19%	0.742	0.39	0.681
10	11	0,1	0,6	67.74%	0.677	0.329	0.488
20	7	0,4	0,1	62.90%	0.629	0.347	0.512
		0,4	0,2	62.90%	0.629	0.347	0.512
25	8	0,2	0,3	72.58%	0.726	0.347	0.537
		0,2	0,4	72.58%	0.726	0.347	0.537
30	8	0,2	0,8	65.57%	0.656	0.489	0.615

Berdasarkan hasil uji coba lanjutan yang dilakukan, didapatkan model terbaik yang digunakan untuk metode HIMDFA adalah model dengan jumlah *scale* 5, nilai *hidden node* 8, *learning rate*

1, dengan nilai *momentum* 0,1 dan 0,2. Model tersebut menghasilkan nilai *accuracy* sebesar 74.19%, *sensitifity* 0.742, *specificity* 0.39, dan *AUC* sebesar 0.681.

*(Halaman ini sengaja dikosongkan)*

## BAB VII KESIMPULAN DAN SARAN

Pada bagian ini berisikan kesimpulan dari hasil penelitian yang telah dilakukan serta saran dari penulis untuk penelitian kedepannya, sehingga dapat menghasilkan penelitian yang lebih mendalam dan bervariasi terhadap topik penelitian ini.

### 7.1. Kesimpulan

Kesimpulan yang dapat diambil dari penelitian ini adalah

1. Hasil parameter terbaik yang dihasilkan adalah *local scaling exponent* berdasarkan skewness pada *scale* < 92 dan *local scaling exponent* berdasarkan kurtosis pada *scale* < 92, dengan nilai p-value secara berurutan 0,004 dan 0,003. Pada prognosis baik, rata-rata nilai parameter *local scaling exponent* berdasarkan skewness pada *scale* < 92 bernilai  $0.25 \pm 0.004$ . Sedangkan pada rata-rata nilai *local scaling exponent* berdasarkan kurtosis pada *scale* < 92 bernilai  $0.42 \pm 0.006$ . Pada prognosis buruk, rata-rata nilai parameter *local scaling exponent* berdasarkan skewness pada *scale* < 92 bernilai  $0.09 \pm 0.006$ . Sedangkan pada rata-rata nilai *local scaling exponent* berdasarkan kurtosis pada *scale* < 92 bernilai  $0.13 \pm 0.008$ .
2. Volatilitas pada data *long term* pasien prognosis baik cenderung memiliki kecondongan data bernilai positif dan memiliki perbedaan *range* data yang lebih tinggi, sedangkan pada pasien prognosis baik cenderung bernilai negatif dan memiliki perbedaan *range* data yang lebih rendah.
3. Tidak adanya perubahan secara konvergen jumlah parameter yang lolos uji signifikansi terhadap penambahan ataupun pengurangan jumlah *scale*.
4. Parameter fungsi fluktuasi dan *local scaling exponent* pada *scale* berdasarkan *skewness* dan *kurtosis* dapat digunakan

sebagai alternatif parameter karena dari 8 parameter yang dilakukan uji signifikansi, cukup banyak parameter yang signifikan. Pada parameter *scale* 10, terdapat 4 parameter yang signifikan. Sedangkan pada parameter *scale* 20, terdapat 5 parameter yang signifikan.

5. Model terbaik dari hasil penelitian adalah model model dengan jumlah *scale* 5, *hidden node* 8, *learning rate* 1, *momentum* 0,1 dan 0,2. Model tersebut menghasilkan nilai *accuracy* sebesar 74.19%, *sensitiftity* 0.742, *specificity* 0.39, dan *AUC* sebesar 0.681.

## 7.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan, saran yang dapat diberikan untuk pengembanagn penelitian kedepannya, antara lain:

1. Menggunakan lebih banyak parameter yang dilakukan *trial error*, seperti *learning rate*, *momentum* dan *epoch*. sehingga dapat menghasilkan lebih banyak variasi model.
2. Menggunakan lebih banyak data penelitian, sehingga performa sistem yang dihasilkan dapat lebih baik.
3. Pada penelitian ini hasil penelitian masih belum berupa aplikasi yang dapat digunakan langsung untuk melakukan ekstraksi fitur dan klasifikasi. Sehingga pada penelitian selanjutnya dapat dilakukan pembuatan aplikasi.
4. Performa dari HOMDFA harus dilakukan validasi dengan menggunakan data prognosis pasien ICU dewasa dengan diagnosis yang lain karena hasil dari penelitian ini belum tentu cocok digunakan untuk data prognosis lain.

## DAFTAR PUSTAKA

- [1] S. M. Rao and T. Suhasini, "Organization of intensive care unit and predicting outcome of critical illness," *Indian J. Anaesth.*, vol. 47, no. 5, pp. 328–337, 2003.
- [2] M. B. Alam, G. Jones, A. J. E. Seely, W. F. S. Poehlman, and M. V. Kamath, "Heart Rate Variability in the Intensive Care Unit," in *Heart Rate Variability (HRV) Signal Analysis: Clinical Applications - Google Books*, M. V. Kamath, M. A. Watanabe, and A. R. M. Upton, Eds. CRC Press, 2013.
- [3] T. L. Hartono, F. D. Setiaji, and I. Setyawan, "Alat bantu analisis heart rate variability," *J. Ilm. Elektron.*, vol. 12, pp. 141–157, 2013.
- [4] L. W. & Wilkins, "ECG Interpretation Made Incredibly Easy." Chris Burghardt, p. 342, 2005.
- [5] G. Ernst, "Heart-Rate Variability—More than Heart Beats?," *Front. Public Heal.*, vol. 5, no. September, pp. 1–12, 2017.
- [6] a. Leite, a. P. Rocha, and M. E. Silva, "Long memory and volatility in HRV: An ARFIMA-GARCH approach," *Comput. Cardiol. 2009*, vol. 3, pp. 165–168, 2009.
- [7] Y. Teng and P. Shang, "Detrended Fluctuation Analysis based on Higher-Order Moments of Financial Time Series," *Phys. A Stat. Mech. its Appl.*, vol. 490, pp. 311–322, 2017.
- [8] N. D. Astuti, "Klasifikasi Penyakit Gagal Jantung Kongestif Menggunakan Artificial Neural Network (ANN) Berdasarkan Ekstraksi Fitur Higher-Order Moments Detrended Fluctuation Analysis pada

Variabilitas Denyut Jantung,” Institut Teknologi Sepuluh Nopember, Surabaya, 2017.

- [9] D. McGonagle, W. Gibbon, and P. Emery, “Classification of inflammatory arthritis by enthesitis,” *Lancet*, vol. 352, no. 9134, pp. 1137–1140, 1998.
- [10] Putu Doddy Heka Ardana, “Aplikasi jaringan syaraf tiruan ( artificial Neural Networks ) dalam modelisasi curah hujan limpasan dengan perbandingan dua algoritma pelatihan ( studi kasus : das tukad jogading ),” *Konf. Nas. Tek. Sipil 7 (KoNTekS 7)*, vol. 7, no. KoNTekS 7, pp. 24–26, 2013.
- [11] P. Ghasemi and M. R. Raoufy, “Prediction of Mortality in Patients with Sepsis Using Detrended Fluctuation Analysis of Heart Rate Variability,” *23rd Iran. Conf. Biomed. Eng. 2016 1st Int. Iran. Conf. Biomed. Eng.*, no. November, pp. 23–25, 2016.
- [12] Nurse.org, “How To Read An Electrocardiogram (EKG/ECG),” 2017. [Online]. Available: <https://nurse.org/articles/how-to-read-an-ECG-or-EKG-electrocardiogram/>.
- [13] M. J. Reed, C. E. Robertson, and P. S. Addison, “Heart rate variability measurements and the prediction of ventricular arrhythmias,” *QJM - Mon. J. Assoc. Physicians*, vol. 98, no. 2, pp. 87–95, 2005.
- [14] P. Azimi, H. R. Mohammadi, E. C. Benzel, S. Shahzadi, S. Azhari, and A. Montazeri, “Artificial neural networks in neurosurgery,” *J. Neurol. Neurosurg. Psychiatry*, vol. 86, no. 3, pp. 251–256, 2015.
- [15] E. P. Kumar and E. P. Sharma, “Artificial Neural Networks-A Study,” *Int. J. Emerg. Eng. Res. Technol.*, vol. 2, no. 2, pp. 143–148, 2014.

- [16] U. Hamida, “Penggunaan Artificial Neural Network (ANN) untuk Memodelkan Kebutuhan Energi untuk Transportasi,” *J. Teknol. dan Manaj.*, vol. 12, pp. 57–65, 2014.
- [17] A. G. Bluman, *Elementary Statistics : A Step By Step Approach, Ninth Edition*, 9th ed. Mc Graw Hill Education, 2014.
- [18] A. F. Hidayatullah, A. D. Prasetyo, and D. P. Sari, “Analisis Kualitas Data dan Klasifikasi Data Pasien Kanker,” *Semin. Nas. Inform. Medis*, pp. 38–47, 2014.
- [19] D. M. Kumar, S. C. Prasannakumar, B. G. Sudarshan, and D. Jayadevappa, “HEART RATE VARIABILITY IS A NOISY TIME SERIES HAVING SELF-SIMILAR AND SELF AFFINE,” *Int. J. Electr. Electron. Eng.*, vol. 2055, no. 1, pp. 23–37, 2009.
- [20] E. Chandrasekhar, S. S. Prabhudesai, G. K. Seemala, and N. Shenvi, “Multifractal detrended fluctuation analysis of ionospheric total electron content data during solar minimum and maximum,” *J. Atmos. Solar-Terrestrial Phys.*, vol. 149, pp. 31–39, 2016.

*(Halaman ini sengaja dikosongkan)*

## BIODATA PENULIS



Penulis lahir di Surabaya pada tanggal 17 April 1996. Penulis merupakan anak kedua dari dua bersaudara. Penulis telah menempuh Pendidikan formal di SD Pacar Keling V/186 Surabaya, SMP negeri 6 Surabaya, dan SMA Negeri 2 Surabaya. Setelah lulus dari SMA, penulis melanjutkan Pendidikan ke jenjang perguruan tinggi negeri di Surabaya yaitu Departemen Sistem Informasi Institut Teknologi Sepuluh

Nopember Surabaya. Sebagai mahasiswa, penulis aktif dalam urusan organisasi dan kepanitian. Tercatat penulis aktif berkontribusi melalui keanggotaan di Himpunan Sistem Informasi pada tahun 2015/2016 sebagai staf departemen dalam negeri dan pada tahun 2016/2017 sebagai kepala divisi internal di departemen dalam negeri. Selain itu, penulis juga aktif berkontribusi melalui keanggotaan kepanitian di *Information Systems Expo* pada tahun 2015 sebagai staf divisi kreatif dan pada tahun 2016 sebagai wakil ketua. Penulis pernah melakukan kerja praktik di Pelindo III Surabaya pada 12 Juni 2017 hingga 7 Agustus 2017. Di Departemen Sistem Informasi ITS, penulis mengambil laboratorium Rekayasa Data dan Intelejensi Bisnis dengan topik tugas akhir Klasifikasi menggunakan *Artificial Neural Network* pada variabilitas denyut jantung. Untuk mengetahui lebih jelas terkait penelitian ini, penulis dapat dihubungi melalui e-mail: fanisifadah@gmail.com.

*(Halaman ini sengaja dikosongkan)*

**LAMPIRAN A**  
**NILAI PARAMETER DAN HASIL UJI SIGNIFIKANSI**  
**PADA DATA DENGAN SCALE 5**

Parameter		Good	Poor	P-value
Fungsi Fluktuasi berdasarkan Skewness	Total	1.16E-49 ± 8.46E-52	3.5E-48 ± 3.99E-49	0.08
	Short Term	9.06E-50 ± 5.95E-52	3.88E-48 ± 4.42E-49	0.09
	Long term	1.33E-49 ± 7.24E-52	3.25E-48 ± 3.65±-49	0.78
Fungsi Fluktuasi berdasarkan Kurtosis	Total	9.72E-66 ± 1.37E-67	4.15E-63 ± 4.88E-64	0.06
	Short Term	5.8E-66 ± 5.5E-68	4.63E-63 ± 5.4E-64	0.06
	Long term	1.23E-65 ± 1.14E-67	3.83E-63 ± 4.46E-64	0.87
Local Scaling Exponent berdasarkan Skewness	Total	0.27 ± 0.004	0.17 ± 0.05	0.0004
	Short Term	0.25 ± 0.004	0.09 ± 0.006	0.004
	Long term	0.28 ± 0.003	0.212 ± 0.004	0.35
Local Scaling Exponent berdasarkan Kurtosis	Total	0.43 ± 0.005	0.28 ± 0.08	0.003
	Short Term	0.42 ± 0.006	0.15 ± 0.008	0.003
	Long term	0.44 ± 0.004	0.34 ± 0.007	0.38

*(Halaman ini sengaja dikosongkan)*

**LAMPIRAN B**  
**NILAI PARAMETER DAN HASIL UJI SIGNIFIKANSI**  
**PADA DATA DENGAN SCALE 10**

Parameter		Good	Poor	P-value
Fungsi Fluktuasi berdasarkan Skewness	Total	1,41E-49 ± 7,67E-51	2,93E-48 ± 2,79E-48	0,81
	Short Term	1,03E-49 ± 5,87E-51	3,23E-48 ± 3,11E-48	0,14
	Long term	1,79E-49 ± 1,06E-51	2,63E-48 ± 2,46E-48	0,53
Fungsi Fluktuasi berdasarkan Kurtosis	Total	1,35E-65 ± 1,34E-66	3,37E-63 ± 3,35E-63	0,83
	Short Term	7,17E-66 ± 5,73E-67	3,76E-63 ± 4,39E-63	0,16
	Long term	1,98E-65 ± 2,51E-66	2,97E-63 ± 2,95E-63	0,38
Local Scaling Exponent berdasarkan Skewness	Total	0,3 ± 0,03	0,18 ± 0,03	0,002
	Short Term	0,26 ± 0,04	0,13 ± 0,04	0,02
	Long term	0,33 ± 0,03	0,22 ± 0,03	0,02
Local Scaling Exponent berdasarkan Kurtosis	Total	0,5 ± 0,04	0,3 ± 0,04	0,001
	Short Term	0,43 ± 0,05	0,25 ± 0,06	0,01
	Long term	0,52 ± 0,05	0,35 ± 0,05	0,02

*(Halaman ini sengaja dikosongkan)*

**LAMPIRAN C**  
**NILAI PARAMETER DAN HASIL UJI SIGNIFIKANSI**  
**PADA DATA DENGAN SCALE 15**

Parameter		Good	Poor	P-value
Fungsi Fluktuasi berdasarkan Skewness	Total	$1.3E-49 \pm 6.9E-52$	$1.37E-49 \pm 1.72E-51$	0.09
	Short Term	$9.44E-50 \pm 4.31E-52$	$1.13E-49 \pm 1.18E-51$	0.06
	Long term	$1.52E-49 \pm 6.17E-52$	$1.59E-49 \pm 1.64E-51$	0.93
Fungsi Fluktuasi berdasarkan Kurtosis	Total	$1.23E-65 \pm 1.13E-67$	$1.3E-65 \pm 3.25E-67$	0.095
	Short Term	$6.47E-66 \pm 4.37E-68$	$8.6E-66 \pm 1.66E-67$	0.07
	Long term	$1.53E-65 \pm 1.04E-67$	$1.67E-65 \pm 3.16E-67$	0.69
Local Scaling Exponent berdasarkan Skewness	Total	$0.2 \pm 0.006$	$0.17 \pm 0.008$	0.11
	Short Term	$0.28 \pm 0.004$	$0.13 \pm 0.005$	0.16
	Long term	$0.29 \pm 0.002$	$0.21 \pm 0.004$	0.04
Local Scaling Exponent berdasarkan Kurtosis	Total	$0.46 \pm 0.09$	$0.29 \pm 0.012$	0.09
	Short Term	$0.47 \pm 0.05$	$0.24 \pm 0.007$	0.13
	Long term	$0.46 \pm 0.04$	$0.34 \pm 0.006$	0.04

*(Halaman ini sengaja dikosongkan)*

**LAMPIRAN D**  
**NILAI PARAMETER DAN HASIL UJI SIGNIFIKANSI**  
**PADA DATA DENGAN SCALE 20**

Parameter		Good	Poor	P-value
Fungsi Fluktuasi berdasarkan Skewness	Total	1,37E-49 ± 6,53E-51	1,61E-45 ± 1,61E-45	0,57
	Short Term	9,40E-50 ± 4,79E-51	1,71E-45 ± 1,71E-45	0,03
	Long term	1,79E-49 ± 1,08E-50	1,52E-45 ± 1,52E-45	0,69
Fungsi Fluktuasi berdasarkan Kurtosis	Total	1,39E-65 ± 1,18E-66	1,91E-59 ± 1,91E-59	0,98
	Short Term	6,49E-66 ± 4,69E-67	2,02E-59 ± 2,02E-59	0,04
	Long term	2,12E-65 ± 2,23E-66	1,80E-59 ± 1,8E-59	0,45
Local Scaling Exponent berdasarkan Skewness	Total	0,346 ± 0,03	0,215 ± 0,03	0,003
	Short Term	0,328 ± 0,05	0,184 ± 0,05	0,07
	Long term	0,364 ± 0,03	0,246 ± 0,03	0,01
Local Scaling Exponent berdasarkan Kurtosis	Total	0,561 ± 0,04	0,362 ± 0,05	0,002
	Short Term	0,550 ± 0,07	0,330 ± 0,07	0,04
	Long term	0,571 ± 0,04	0,394 ± 0,05	0,01



**LAMPIRAN E**  
**NILAI PARAMETER DAN HASIL UJI SIGNIFIKANSI**  
**PADA DATA DENGAN SCALE 25**

Parameter		Good	Poor	P-value
Fungsi Fluktuasi berdasarkan Skewness	Total	$1.34E-49 \pm 6.55E-52$	$2.076 \pm 2.36$	0.02
	Short Term	$1.05E-49 \pm 4.07E-52$	$2.4E-48 \pm 2.65E-49$	0.02
	Long term	$1.6E-49 \pm 5.8E-52$	$1.79E-48 \pm 1.9E-49$	0.69
Fungsi Fluktuasi berdasarkan Kurtosis	Total	$1.25E-65 \pm 1.16E-67$	$2.34E-63 \pm 2.85E-64$	0.01
	Short Term	$7.51E-66 \pm 4.16E-68$	$2.74E-63 \pm 3.2E-64$	0.01
	Long term	$1.7E-65 \pm 1.1E-67$	$1.98E-63 \pm 2.3E-64$	0.52
Local Scaling Exponent berdasarkan Skewness	Total	$0.27 \pm 0.008$	$0.17 \pm 0.012$	0.08
	Short Term	$0.23 \pm 0.003$	$0.11 \pm 0.005$	0.08
	Long term	$0.3 \pm 0.002$	$0.22 \pm 0.003$	0.03
Local Scaling Exponent berdasarkan Kurtosis	Total	$0.45 \pm 0.011$	$0.3 \pm 0.02$	0.05
	Short Term	$0.414 \pm 0.005$	$0.24 \pm 0.007$	0.05
	Long term	$0.5 \pm 0.003$	$0.36 \pm 0.006$	0.02

*(Halaman ini sengaja dikosongkan)*

**LAMPIRAN F**  
**NILAI PARAMETER DAN HASIL UJI SIGNIFIKANSI**  
**PADA DATA DENGAN SCALE 30**

Parameter		Good	Poor	P-value
Fungsi Fluktuasi berdasarkan Skewness	Total	1.52E-49 ± 8.35E-52	1.52E-49 ± 1.9E-51	0.6
	Short Term	1.14E-49 ± 4.9E-52	1.17E-49 ± 1.05E-51	0.31
	Long term	1.9E-49 ± 8.4E-52	1.87E-49 ± 2.23E-51	0.26
Fungsi Fluktuasi berdasarkan Kurtosis	Total	1.55E-65 ± 1.52E-67	1.58E-65 ± 1.9E-51	0.7
	Short Term	8.65E-66 ± 5.42E-68	9.2E-66 ± 1.47E-47	0.37
	Long term	2.2E-65 ± 1.67E-67	2.23E-65 ± 4.78E-67	0.13
Local Scaling Exponent berdasarkan Skewness	Total	0.3 ± 0.009	0.2 ± 0.014	0.1
	Short Term	0.29 ± 0.003	0.18 ± 0.005	0.09
	Long term	0.3 ± 0.002	0.24 ± 0.004	0.043
Local Scaling Exponent berdasarkan Kurtosis	Total	0.5 ± 0.014	0.35 ± 0.022	0.05
	Short Term	0.5 ± 0.004	0.326 ± 0.007	0.04
	Long term	0.5 ± 0.003	0.38 ± 0.006	0.05

*(Halaman ini sengaja dikosongkan)*

**LAMPIRAN G**  
**PERCOBAAN EPOCH 2000 DAN 4000**

<i>Scale</i>	<i>Hidden Node</i>	<i>Epoch</i>	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>	<i>AUC</i>
5	8	4000	62.90%	0.629	0.64	0.685
		2000	66.13%	0.661	0.652	0.68
10	11	4000	54.84%	0.548	0.463	0.552
		2000	61.29%	0.613	0.378	0.565
20	7	4000	58.06%	0.581	0.549	0.467
		2000	54.84%	0.548	0.5	0.525
25	8	4000	69.35%	0.694	0.262	0.532
		2000	72.58%	0.726	0.347	0.537
30	8	4000	60.66%	0.607	0.441	0.585
		2000	60.66%	0.607	0.441	0.566



**LAMPIRAN H**  
**UJI PERFORMA DATA SCALE 5 PADA HIDDEN NODE 8**  
**DAN EPOCH 2000**

Learning Rate	Momentum	Accuracy	Sensitifity	Specifity	ROC	Confussion Matrix [TP,FP],[FN,TN]
0,1	0,1	69.35%	0.694	0.408	0.68	[39,6],[13,4]
	0,2	74.19%	0.742	0.39	0.681	[43,2],[14,3]
	0,3	74.19%	0.742	0.39	0.681	[43,2],[14,3]
	0,4	69.35%	0.694	0.408	0.68	[39,6],[13,4]
	0,5	67.74%	0.677	0.512	0.681	[35,10],[10,7]
	0,6	64.52%	0.645	0.573	0.68	[31,14],[8,9]
	0,7	64.52%	0.645	0.646	0.682	[29,16],[6,11]
	0,8	74.19%	0.742	0.317	0.65	[45,0],[16,0]
	0,9	50.00%	0.5	0.738	0.651	[16,29],[2,15]
0,2	0,1	64.52%	0.645	0.537	0.678	[32,13],[9,8]
	0,2	64.52%	0.645	0.573	0.68	[31,14],[8,9]
	0,3	64.52%	0.645	0.61	0.681	[30,15],[7,10]
	0,4	64.52%	0.645	0.646	0.682	[29,16],[6,11]
	0,5	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,6	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,7	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,8	54.84%	0.548	0.72	0.652	[20,25],[3,14]
	0,9	35.48%	0.355	0.683	0.65	[7,38],[2,15]
0,3	0,1	62.90%	0.629	0.64	0.68	[28,17],[6,11]

## H-2

Learning Rate	Momentum	Accuracy	Sensitivity	Specificity	ROC	Confusion Matrix [TP,FP],[FN,TN]
	0,2	62.90%	0.629	0.64	0.68	[28,17],[6,11]
	0,3	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,4	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,5	74.1935	0.742	0.317	0.644	[45,0],[16,1]
	0,6	74.1935	0.742	0.353	0.65	[44,1],[15,2]
	0,7	61.2903	0.613	0.707	0.651	[25,20],[4,13]
	0,8	51.61%	0.516	0.744	0.65	[17,28],[2,15]
	0,9	35.48%	0.355	0.72	0.668	[6,39],[1,16]
0,4	0,1	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,2	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,3	74.19%	0.742	0.317	0.65	[45,0],[16,0]
	0,4	72.58%	0.729	0.311	0.644	[44,1],[16,1]
	0,5	72.58%	0.726	0.347	0.647	[43,2],[15,2]
	0,6	61.29%	0.613	0.671	0.65	[26,19],[5,12]
	0,7	56.45%	0.565	0.689	0.651	[22,23],[4,13]
	0,8	51.61%	0.516	0.744	0.65	[17,28],[2,15]
	0,9	32.26%	0.323	0.707	0.613	[4,41],[1,16]
0,5	0,1	74.19%	0.742	0.317	0.65	[45,0],[16,0]
	0,2	72.58%	0.729	0.311	0.644	[44,1],[16,1]
	0,3	72.58%	0.729	0.311	0.644	[44,1],[16,1]
	0,4	70.97%	0.71	0.341	0.646	[42,3],[15,2]
	0,5	62.90%	0.629	0.64	0.65	[28,17],[6,11]
	0,6	61.29%	0.613	0.671	0.65	[26,19],[5,12]

Learning Rate	Momentum	Accuracy	Sensitifty	Specifity	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,7	58.06%	0.581	0.695	0.647	[23,22],[4,13]
	0,8	51.61%	0.516	0.744	0.65	[17,28],[2,15]
	0,9	30.65%	0.306	0.738	0.565	[2,43],[0,17]
0,6	0,1	74.19%	0.742	0.353	0.646	[44,1],[15,2]
	0,2	70.97%	0.71	0.341	0.646	[42,3],[15,2]
	0,3	64.52%	0.645	0.427	0.645	[35,10],[12,5]
	0,4	62.90%	0.629	0.677	0.644	[27,18],[5,12]
	0,5	61.29%	0.613	0.671	0.65	[26,19],[5,12]
	0,6	61.2903	0.613	0.707	0.651	[25,20],[4,13]
	0,7	59.68%	0.597	0.701	0.648	[24,21],[4,13]
	0,8	46.77%	0.468	0.726	0.671	[14,31],[2,15]
	0,9	43.55%	0.435	0.75	0.65	[11,34],[1,16]
0,7	0,1	58.06%	0.581	0.476	0.646	[29,16],[10,7]
	0,2	62.90%	0.629	0.677	0.644	[27,18],[5,12]
	0,3	61.29%	0.613	0.671	0.65	[26,19],[5,12]
	0,4	61.2903	0.613	0.707	0.651	[25,20],[4,13]
	0,5	61.2903	0.613	0.707	0.651	[25,20],[4,13]
	0,6	61.29%	0.613	0.671	0.65	[26,19],[5,12]
	0,7	62.90%	0.629	0.604	0.643	[29,16],[7,10]
	0,8	35.48%	0.355	0.683	0.663	[7,38],[2,15]
	0,9	72.58%	0.726	0.274	0.648	[45,0],[17,0]
0,8	0,1	62.90%	0.629	0.713	0.646	[26,19],[4,13]
	0,2	61.2903	0.613	0.707	0.651	[25,20],[4,13]

# H-4

Learning Rate	Momentum	Accuracy	Sensitifity	Specificity	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,3	59.68%	0.597	0.701	0.648	[24,21],[4,13]
	0,4	58.06%	0.581	0.695	0.648	[23,22],[4,13]
	0,5	59.68%	0.597	0.701	0.648	[24,21],[4,13]
	0,6	64.52%	0.645	0.646	0.682	[29,16],[6,11]
	0,7	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,8	34%	0.339	0.714	0.648	[5,40],[1,16]
	0,9	72.58%	0.726	0.274	0.648	[45,0],[17,0]
0,9	0,1	58.06%	0.581	0.695	0.648	[23,22],[4,13]
	0,2	58.06%	0.581	0.695	0.648	[23,22],[4,13]
	0,3	58.06%	0.581	0.695	0.648	[23,22],[4,13]
	0,4	58.06%	0.581	0.695	0.648	[23,22],[4,13]
	0,5	61.2903	0.613	0.707	0.651	[25,20],[4,13]
	0,6	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,7	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,8	35%	0.339	0.714	0.625	[5,40],[1,16]
	0,9	72.58%	0.726	0.274	0.648	[45,0],[17,0]

**LAMPIRAN I**  
**UJI PERFORMA DATA SCALE 10 PADA HIDDEN NODE**  
**11 DAN EPOCH 2000**

Learning Rate	Momentum	Accuracy	Sensitifity	Specificity	ROC	Confussion Matrix [TP,FP],[FN,TN]
0,1	0,1	65%	0.645	0.317	0.482	[38,7],[15,2]
	0,2	69%	0.694	0.299	0.481	[42,3],[16,1]
	0,3	61%	0.613	0.305	0.481	[36,9],[15,2]
	0,4	61%	0.613	0.305	0.488	[36,9],[15,2]
	0,5	61.29%	0.613	0.305	0.485	[36,9],[15,2]
	0,6	67.74%	0.677	0.329	0.488	[40,5],[15,2]
	0,7	64.52%	0.645	0.5	0.573	[33,12],[10,7]
	0,8	61.29%	0.613	0.341	0.497	[35,10],[14,3]
	0,9	43.55%	0.435	0.531	0.515	[17,28],[7,10]
0,2	0,1	63%	0.629	0.384	0.529	[35,10],[13,4]
	0,2	63%	0.629	0.384	0.595	[35,10],[13,4]
	0,3	61%	0.613	0.378	0.565	[34,11],[13,4]
	0,4	63%	0.629	0.421	0.601	[34,11],[12,5]
	0,5	62.90%	0.629	0.53	0.562	[31.14],[9,8]
	0,6	61.29%	0.613	0.341	0.501	[35,10],[14,3]
	0,7	50.00%	0.5	0.445	0.506	[24,21],[10,7]
	0,8	41.94%	0.419	0.524	0.505	[16,29],[7,10]
	0,9	37.00%	0.371	0.726	0.52	[7,38],[1,16]
0,3	0,1	66%	0.661	0.469	0.612	[35,10],[11,6]

Learning Rate	Momentum	Accuracy	Sensitivity	Specificity	ROC	Confusion Matrix [TP,FP],[FN,TN]
	0,2	66%	0.661	0.579	0.608	[32,13],[8,9]
	0,3	61%	0.613	0.598	0.584	[28,17],[7,10]
	0,4	61%	0.613	0.341	0.508	[35,10],[14,3]
	0,5	58.06%	0.581	0.476	0.51	[29,16],[10,7]
	0,6	45.16%	0.452	0.427	0.507	[21,24],[10,7]
	0,7	45.16%	0.452	0.537	0.501	[18,27],[7,10]
	0,8	40.32%	0.403	0.665	0.501	[11,34],[3,14]
	0,9	35.48%	0.355	0.72	0.51	[6,39],[1,16]
0,4	0,1	56%	0.565	0.506	0.6	[27,18],[9,8]
	0,2	63%	0.629	0.384	0.506	[35,10],[13,4]
	0,3	58%	0.581	0.476	0.512	[29,16],[10,7]
	0,4	48%	0.484	0.439	0.51	[23,22],[10,7]
	0,5	45.16%	0.452	0.427	0.506	[21,24],[10,7]
	0,6	45.16%	0.452	0.537	0.502	[18,27],[7,10]
	0,7	45.16%	0.452	0.61	0.502	[16,29],[5,12]
	0,8	38.80%	0.387	0.732	0.497	[8,37],[1,16]
	0,9	35.48%	0.355	0.683	0.519	[7,38],[2,15]
0,5	0,1	58%	0.581	0.476	0.512	[29,16],[10,7]
	0,2	52%	0.516	0.451	0.512	[25,20],[10,7]
	0,3	45%	0.452	0.427	0.508	[21,24],[10,7]
	0,4	45%	0.452	0.463	0.502	[20,25],[9,8]
	0,5	45%	0.452	0.537	0.503	[18,27],[7,10]
	0,6	43.55%	0.435	0.567	0.502	[16,29],[6,11]

Learning Rate	Momentum	Accuracy	Sensitify	Specificity	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,7	38.71%	0.387	0.659	0.497	[10,35],[3,14]
	0,8	37.10%	0.371	0.689	0.493	[8,37],[2,15]
	0,9	33.87%	0.339	0.677	0.528	[6,39],[2,15]
0,6	0,1	47%	0.468	0.433	0.511	[22,23],[10,7]
	0,2	45%	0.452	0.427	0.511	[21,24],[10,7]
	0,3	47%	0.468	0.543	0.503	[19,26],[7,10]
	0,4	45%	0.452	0.537	0.503	[18,27],[7,10]
	0,5	43.55%	0.435	0.567	0.503	[16,29],[6,11]
	0,6	38.79%	0.387	0.585	0.498	[12,33],[5,12]
	0,7	35.48%	0.355	0.61	0.492	[9,36],[4,13]
	0,8	35.48%	0.355	0.683	0.49	[7,38],[2,15]
	0,9	33.87%	0.339	0.677	0.548	[6,39],[2,15]
0,7	0,1	48%	0.484	0.512	0.51	[21,24],[8,9]
	0,2	45%	0.452	0.537	0.505	[18,27],[7,10]
	0,3	44%	0.435	0.531	0.505	[17,28],[7,10]
	0,4	44%	0.435	0.567	0.501	[16,29],[6,11]
	0,5	40.00%	0.403	0.592	0.495	[13,32],[5,12]
	0,6	37.10%	0.371	0.616	0.492	[10,35],[4,13]
	0,7	37.10%	0.371	0.689	0.49	[8,37],[2,15]
	0,8	33.87%	0.339	0.677	0.497	[6,39],[2,15]
	0,9	58.06%	0.581	0.695	0.592	[23,22],[4,13]
0,8	0,1	45%	0.452	0.537	0.506	[18,27],[7,10]
	0,2	45%	0.452	0.573	0.506	[17,28],[6,11]

Learning Rate	Momentum	Accuracy	Sensitivity	Specificity	ROC	Confusion Matrix [TP,FP],[FN,TN]
	0,3	44%	0.435	0.567	0.501	[16,29],[6,11]
	0,4	42%	0.419	0.598	0.501	[14,31],[5,12]
	0,5	35.48%	0.355	0.573	0.492	[10,35],[5,12]
	0,6	35.48%	0.355	0.61	0.49	[9,36],[4,13]
	0,7	37.10%	0.371	0.689	0.49	[8,37],[2,15]
	0,8	34%	0.339	0.677	0.497	[6,39],[2,15]
	0,9	32%	0.323	0.707	0.527	[4,41],[1,16]
0,9	0,1	44%	0.435	0.567	0.506	[16,29],[6,11]
	0,2	44%	0.435	0.567	0.498	[16,29],[6,11]
	0,3	42%	0.419	0.598	0.498	[14,31],[5,12]
	0,4	40%	0.403	0.628	0.497	[12,33],[4,13]
	0,5	35.48%	0.355	0.61	0.493	[9,36],[4,13]
	0,6	37.10%	0.371	0.653	0.49	[9,36],[3,14]
	0,7	37.10%	0.371	0.689	0.493	[8,37],[2,15]
	0,8	34%	0.339	0.677	0.499	[6,39],[2,15]
	0,9	35%	0.355	0.72	0.473	[6,39],[1,16]

**LAMPIRAN J**  
**UJI PERFORMA DATA SCALE 20 PADA HIDDEN NODE**  
**7 DAN EPOCH 2000**

Learning Rate	Momentum	Accuracy	Sensitifity	Specificity	ROC	Confussion Matrix [TP,FP],[FN,TN]
0,1	0,1	62.90%	0.629	0.347	0.512	[36,9],[14,3]
	0,2	62.90%	0.629	0.347	0.512	[36,9],[14,3]
	0,3	58.06%	0.581	0.402	0.523	[31,14],[12,5]
	0,4	51.61%	0.516	0.415	0.51	[26,19],[11,6]
	0,5	50.00%	0.5	0.408	0.508	[25,20],[11,6]
	0,6	50.00%	0.5	0.445	0.516	[24,21],[10,7]
	0,7	56.45%	0.565	0.36	0.498	[31,14],[13,4]
	0,8	59.68%	0.597	0.445	0.502	[31,14],[11,6]
0,2	0,1	50.00%	0.5	0.482	0.511	[23,22],[9,8]
	0,2	51.61%	0.516	0.488	0.528	[24,21],[9,8]
	0,3	54.84%	0.548	0.5	0.535	[26,19],[9,8]
	0,4	53.23%	0.532	0.347	0.51	[29,16],[13,4]
	0,5	56.45%	0.565	0.36	0.512	[31,14],[13,4]
	0,6	59.68%	0.597	0.408	0.519	[32,13],[12,5]
	0,7	59.68%	0.597	0.445	0.497	[31,14],[11,6]
	0,8	53.23%	0.532	0.53	0.525	[24,21],[8,9]
	0,9	48.39%	0.484	0.402	0.475	[24,21],[11,6]
0,3	0,1	53.23%	0.532	0.347	0.506	[29,16],[13,4]
	0,2	54.84%	0.548	0.427	0.529	[28,17],[11,6]
	0,3	58.06%	0.581	0.402	0.523	[31,14],[12,5]
	0,4	54.84%	0.548	0.39	0.518	[29,16],[12,5]
	0,5	56.4516	0.565	0.433	0.512	[29,16],[11,6]

Learning Rate	Momentum	Accuracy	Sensitifity	Specificity	ROC	Confussion Matrix
						[TP,FP],[FN,TN]
	0,6	56.4516	0.565	0.469	0.553	[28,17],[10,7]
	0,7	61.29%	0.613	0.451	0.553	[32,13],[11,6]
	0,8	51.61%	0.516	0.451	0.45	[25,20],[10,7]
	0,9	40.32%	0.403	0.701	0.536	[10,35],[2,15]
0,4	0,1	61.29%	0.613	0.451	0.553	[32,13],[11,6]
	0,2	61.29%	0.613	0.451	0.553	[32,13],[11,6]
	0,3	54.84%	0.548	0.427	0.529	[28,17],[11,6]
	0,4	54.84%	0.548	0.427	0.529	[28,17],[11,6]
	0,5	53.34%	0.532	0.494	0.529	[25,20],[9,8]
	0,6	53.23%	0.532	0.567	0.556	[23,22],[7,10]
	0,7	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,8	48.39%	0.484	0.732	0.552	[15,30],[2,15]
0,5	0,1	53.23%	0.532	0.421	0.544	[27,18],[11,6]
	0,2	56.45%	0.565	0.506	0.574	[27,18],[9,8]
	0,3	53.23%	0.532	0.494	0.528	[25,20],[9,8]
	0,4	53.23%	0.532	0.494	0.531	[25,20],[9,8]
	0,5	53.23%	0.532	0.494	0.531	[25,20],[9,8]
	0,6	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,7	53.23%	0.532	0.75	0.569	[18,27],[2,15]
	0,8	38.71%	0.387	0.622	0.43	[11,34],[4,13]
	0,9	40.32%	0.403	0.701	0.531	[10,35],[2,15]
0,6	0,1	48.39%	0.484	0.439	0.514	[23,22],[10,7]
	0,2	53.23%	0.532	0.494	0.531	[25,20],[9,8]
	0,3	53.23%	0.532	0.494	0.531	[25,20],[9,8]
	0,4	51.61%	0.516	0.524	0.552	[23,22],[9,8]
	0,5	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,6	40.32%	0.403	0.701	0.531	[10,35],[2,15]

Learning Rate	Momentum	Accuracy	Sensitivity	Specificity	ROC	Confusion Matrix
						[TP,FP],[FN,TN]
	0,7	51.61%	0.516	0.744	0.567	[17,28],[2,15]
	0,8	37.10%	0.371	0.689	0.54	[8,37],[2,15]
	0,9	40.32%	0.403	0.701	0.531	[10,35],[2,15]
0,7	0,1	59.68%	0.597	0.628	0.571	[26,19],[6,11]
	0,2	51.61%	0.516	0.488	0.557	[24,21],[9,8]
	0,3	50.00%	0.5	0.482	0.511	[23,22],[9,8]
	0,4	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,5	40.32%	0.403	0.701	0.531	[10,35],[2,15]
	0,6	51.61%	0.516	0.744	0.567	[17,28],[2,15]
	0,7	50.00%	0.5	0.738	0.584	[16,29],[2,15]
	0,8	37.10%	0.371	0.689	0.542	[8,37],[2,15]
	0,9	72.58%	0.726	0.274	0.493	[45,0],[17,0]
0,8	0,1	51.61%	0.516	0.488	0.557	[24,21],[9,8]
	0,2	50.00%	0.5	0.482	0.66	[23,22],[9,8]
	0,3	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,4	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,5	53.23%	0.32	0.75	0.57	[18,27],[2,15]
	0,6	51.61%	0.516	0.744	0.567	[17,28],[2,15]
	0,7	50.00%	0.5	0.628	0.5	[19,26],[5,12]
	0,8	37%	0.371	0.689	0.545	[8,37],[2,15]
	0,9	40.32%	0.403	0.701	0.531	[10,35],[2,15]
0,9	0,1	50.00%	0.5	0.482	0.66	[23,22],[9,8]
	0,2	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,3	41.94%	0.419	0.707	0.522	[11,34],[2,15]
	0,4	40.32%	0.403	0.701	0.531	[10,35],[2,15]
	0,5	51.61%	0.516	0.744	0.567	[17,28],[2,15]
	0,6	51.61%	0.516	0.744	0.567	[17,28],[2,15]
	0,7	51.61%	0.516	0.744	0.567	[17,28],[2,15]

J-4

Learning Rate	Momentum	Accuracy	Sensitifty	Specificity	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,8	37%	0.371	0.689	0.545	[8,37],[2,15]
	0,9	40.32%	0.403	0.701	0.531	[10,35],[2,15]

**LAMPIRAN K**  
**UJI PERFORMA DATA SCALE 25 PADA HIDDEN NODE**  
**8 DAN EPOCH 2000**

Learning Rate	Momentum	Accuracy	Sensitifity	Specifitiy	ROC	Confussion Matrix [TP,FP],[FN,TN]
0,1	0,1	72.58%	0.726	0.274	0.648	[45,0],[17,0]
	0,2	62.90%	0.629	0.421	0.604	[34,11],[12,5]
	0,3	61.29%	0.613	0.488	0.579	[31,14],[10,7]
	0,4	58.06%	0.81	0.476	0.59	[29,16],[10,7]
	0,5	56.45%	0.565	0.469	0.593	[28,17],[10,7]
	0,6	64.52%	0.645	0.354	0.544	[37,8],[14,3]
	0,7	69.35%	0.694	0.262	0.537	[43,2],[17,0]
	0,8	62.90%	0.629	0.421	0.604	[34,11],[12,5]
	0,9	30.65%	0.306	0.592	0.537	[6,39],[4,13]
0,2	0,1	62.90%	0.629	0.494	0.566	[32,13],[10,7]
	0,2	66.13%	0.661	0.396	0.544	[37,8],[13,4]
	0,3	72.58%	0.726	0.347	0.537	[43,2],[15,2]
	0,4	72.58%	0.726	0.347	0.537	[43,2],[15,2]
	0,5	69.35%	0.694	0.408	0.537	[39,6],[13,4]
	0,6	61.29%	0.613	0.451	0.536	[32,13],[11,6]
	0,7	51.61%	0.516	0.488	0.537	[24,21],[9,8]
	0,8	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,9	29.03%	0.29	0.659	0.536	[3,42],[2,15]
0,3	0,1	69.35%	0.694	0.372	0.536	[40,5],[14,3]

K-2

Learning Rate	Momentum	Accuracy	Sensitifity	Specifitiy	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,2	69.35%	0.694	0.445	0.537	[38,7],[12,5]
	0,3	62.90%	0.629	0.421	0.604	[34,11],[12,5]
	0,4	59.68%	0.597	0.482	0.537	[30,15],[10,7]
	0,5	54.8387	0.548	0.5	0.537	[26,19],[9,8]
	0,6	45.1613	0.452	0.61	0.524	[16,29],[5,12]
	0,7	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,8	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,9	29.03%	0.29	0.659	0.536	[3,42],[2,15]
0,4	0,1	61.29%	0.613	0.451	0.536	[32,13],[11,6]
	0,2	58.06%	0.81	0.476	0.59	[29,16],[10,7]
	0,3	53.23%	0.532	0.457	0.536	[26,19],[10,7]
	0,4	50.00%	0.5	0.555	0.535	[21,24],[7,10]
	0,5	37.10%	0.371	0.616	0.518	[10,35],[4,13]
	0,6	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,7	30.65%	0.306	0.665	0.532	[4,41],[2,15]
	0,8	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,9	27.42%	0.274	0.579	0.541	[4,41],[4,13]
0,5	0,1	54.8387	0.548	0.5	0.537	[26,19],[9,8]
	0,2	51.61%	0.516	0.488	0.537	[24,21],[9,8]
	0,3	45.1613	0.452	0.61	0.524	[16,29],[5,12]
	0,4	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,5	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,6	29.03%	0.29	0.622	0.524	[4,41],[3,14]

Learning Rate	Momentum	Accuracy	Sensitifiy	Specifitiy	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,7	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,8	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,9	61.29%	0.613	0.634	0.556	[27,18],[6,11]
0,6	0,1	48.39%	0.484	0.622	0.529	[18,27],[5,12]
	0,2	38.71%	0.387	0.622	0.514	[11,34],[4,13]
	0,3	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,4	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,5	29.03%	0.29	0.622	0.518	[4,41],[3,14]
	0,6	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,7	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,8	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,9	27.42%	0.274	0.579	0.541	[4,41],[4,13]
0,7	0,1	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,2	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,3	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,4	29.03%	0.29	0.622	0.518	[4,41],[3,14]
	0,5	30.65%	0.306	0.665	0.532	[4,41],[2,15]
	0,6	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,7	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,8	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,9	46.77%	0.468	0.616	0.54	[17,28],[5,12]
0,8	0,1	30.65%	0.306	0.592	0.536	[6,39],[4,13]
	0,2	30.65%	0.306	0.592	0.536	[6,39],[4,13]

Learning Rate	Momentum	Accuracy	Sensitifity	Specifitiy	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,3	29.03%	0.29	0.622	0.518	[4,41],[3,14]
	0,4	30.65%	0.306	0.665	0.532	[4,41],[2,15]
	0,5	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,6	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,7	27.42%	0.274	0.653	0.392	[2,43],[2,15]
	0,8	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,9	72.58%	0.726	0.274	0.648	[45,0],[17,0]
0,9	0,1	32.26%	0.323	0.634	0.515	[6,39],[3,14]
	0,2	29.03%	0.29	0.622	0.518	[4,41],[3,14]
	0,3	29.03%	0.29	0.622	0.518	[4,41],[3,14]
	0,4	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,5	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,6	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,7	27.42%	0.274	0.653	0.392	[2,43],[2,15]
	0,8	29.03%	0.29	0.659	0.536	[3,42],[2,15]
	0,9	72.58%	0.726	0.274	0.648	[45,0],[17,0]

**LAMPIRAN L**  
**UJI PERFORMA DATA SCALE 30 PADA HIDDEN NODE**  
**8 DAN EPOCH 2000**

Learning Rate	Momentum	Accuracy	Sensitifity	Specifitiy	ROC	Confussion Matrix [TP,FP],[FN,TN]
0,1	0,1	62.30%	0.623	0.45	0.563	[33,6],[17,5]
	0,2	60.66%	0.607	0.441	0.559	[32,17],[17,5]
	0,3	60.66%	0.607	0.441	0.556	[32,17],[17,5]
	0,4	60.66%	0.607	0.441	0.558	[32,17],[17,5]
	0,5	60.66%	0.607	0.441	0.561	[32,17],[17,5]
	0,6	60.66%	0.607	0.441	0.565	[33,6],[17,5]
	0,7	62.30%	0.623	0.45	0.555	[32,17],[17,5]
	0,8	60.66%	0.607	0.441	0.523	[32,17],[17,5]
	0,9	62.30%	0.623	0.431	0.502	[34,5],[18,4]
0,2	0,1	60.66%	0.607	0.441	0.568	[32,7],[17,5]
	0,2	60.66%	0.607	0.441	0.566	[32,7],[17,5]
	0,3	60.66%	0.607	0.441	1.566	[32,7],[16,6]
	0,4	62.30%	0.623	0.47	0.579	[32,7],[17,5]
	0,5	62.30%	0.623	0.47	0.578	[32,7],[16,6]
	0,6	62.30%	0.623	0.47	0.591	[32,7],[16,6]
	0,7	62.30%	0.623	0.431	0.561	[34,5],[18,4]
	0,8	65.57%	0.656	0.489	0.615	[34,5],[16,6]
	0,9	63.93%	0.639	0.361	0.571	[39,0],[22,0]
0,3	0,1	62.30%	0.623	0.47	0.568	[32,7],[16,6]

Learning Rate	Momentum	Accuracy	Sensitivity	Specifitiy	ROC	Confusion Matrix [TP,FP],[FN,TN]
	0,2	62.30%	0.623	0.47	0.586	[32,7],[16,6]
	0,3	62.30%	0.623	0.47	0.585	[32,7],[16,7]
	0,4	62.30%	0.623	0.47	0.58	[32,7],[16,6]
	0,5	62.30%	0.623	0.47	0.58	[32,7],[16,6]
	0,6	62.30%	0.623	0.431	0.558	[34,5],[18,4]
	0,7	63.93%	0.639	0.48	0.591	[33,6],[16,6]
	0,8	60.66%	0.607	0.382	0.551	[35,4],[20,2]
	0,9	63.93%	0.639	0.361	0.564	[39,0],[22,0]
0,4	0,1	62.30%	0.623	0.47	0.587	[32,7],[16,6]
	0,2	62.30%	0.623	0.47	0.582	[32,7],[16,6]
	0,3	62.30%	0.623	0.47	0.586	[32,7],[16,6]
	0,4	62.30%	0.623	0.47	0.582	[32,7],[16,6]
	0,5	62.30%	0.623	0.431	0.559	[34,5],[18,4]
	0,6	63.93%	0.639	0.48	0.608	[33,6],[16,6]
	0,7	62.30%	0.623	0.411	0.544	[35,4],[19,3]
	0,8	62.30%	0.623	0.411	0.545	[35,4],[19,3]
	0,9	63.93%	0.639	0.361	0.528	[39,0],[22,0]
0,5	0,1	62.30%	0.623	0.47	0.583	[32,7],[16,6]
	0,2	62.30%	0.623	0.47	0.578	[32,7],[16,6]
	0,3	62.30%	0.623	0.47	0.58	[32,7],[16,6]
	0,4	63.93%	0.639	0.48	0.591	[33,6],[16,6]
	0,5	62.30%	0.623	0.45	0.554	[33,6],[17,5]
	0,6	62.30%	0.623	0.411	0.543	[35,4],[19,3]

Learning Rate	Momentum	Accuracy	Sensitifity	Specifitiy	ROC	Confussion Matrix [TP,FP],[FN,TN]
	0,7	62.30%	0.623	0.411	0.555	[35,4],[19,3]
	0,8	59.02%	0.59	0.392	0.521	[33,6],[19,3]
	0,9	63.93%	0.639	0.361	0.541	[39,0],[22,0]
0,6	0,1	60.66%	0.607	0.461	0.579	[31,8],[16,6]
	0,2	62.30%	0.623	0.47	0.589	[32,7],[16,6]
	0,3	63.93%	0.639	0.48	0.587	[33,6],[17,5]
	0,4	62.30%	0.623	0.45	0.554	[33,6],[16,6]
	0,5	62.30%	0.623	0.411	0.552	[35,4],[19,3]
	0,6	62.30%	0.623	0.411	0.547	[35,4],[19,3]
	0,7	62.30%	0.623	0.411	0.569	[35,4],[19,3]
	0,8	63.93%	0.639	0.361	0.536	[39,0],[22,0]
	0,9	63.93%	0.639	0.361	0.523	[39,0],[22,0]
0,7	0,1	62.30%	0.623	0.47	0.587	[32,7],[16,6]
	0,2	62.30%	0.623	0.47	0.589	[32,7],[16,6]
	0,3	62.30%	0.623	0.45	0.555	[33,6],[17,5]
	0,4	62.30%	0.623	0.411	0.576	[35,4],[19,3]
	0,5	62.30%	0.623	0.411	0.541	[35,4],[19,3]
	0,6	62.30%	0.623	0.411	0.568	[35,4],[19,3]
	0,7	62.30%	0.623	0.411	0.564	[35,4],[19,3]
	0,8	63.93%	0.639	0.361	0.534	[39,0],[22,0]
	0,9	63.93%	0.639	0.361	0.569	[39,0],[22,0]
0,8	0,1	62.30%	0.623	0.47	0.591	[32,7],[16,6]
	0,2	59%	0.59	0.392	0.529	[33,6],[19,3]

Learning Rate	Momentum	Accuracy	Sensitifty	Specifitiy	ROC	Confusion Matrix [TP,FP],[FN,TN]
	0,3	62.30%	0.623	0.411	0.548	[35,4],[19,3]
	0,4	62.30%	0.623	0.411	0.543	[35,4],[19,3]
	0,5	62.30%	0.623	0.411	0.57	[35,4],[19,3]
	0,6	60.66%	0.607	0.382	0.52	[35,4],[20,2]
	0,7	63.93%	0.639	0.361	0.571	[39,0],[22,0]
	0,8	63.93%	0.639	0.361	0.531	[39,0],[22,0]
	0,9	63.93%	0.639	0.361	0.568	[39,0],[22,0]
0,9	0,1	63.93%	0.639	0.48	0.144	[33,6],[16,6]
	0,2	62%	0.623	0.411	0.535	[25,4],[19,3]
	0,3	62%	0.623	0.411	0.545	[35,4],[19,3]
	0,4	62%	0.623	0.411	0.568	[35,4],[19,3]
	0,5	57%	0.574	0.363	0.54	[33,6],[20,2]
	0,6	64%	0.639	0.361	0.566	[39,0],[22,0]
	0,7	64%	0.639	0.361	0.575	[39,0],[22,0]
	0,8	64%	0.639	0.361	0.528	[39,0],[22,0]
	0,9	64%	0.639	0.361	0.565	[39,0],[22,0]