



ITS

Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS 141501

**PENERAPAN METODE ARTIFICIAL NEURAL NETWORK
(ANN) UNTUK PERAMALAN INFLASI DI INDONESIA**

***APPLICATION OF ARTIFICIAL NEURAL NETWORK
(ANN) FOR INFLATION FORECASTING IN INDONESIA***

RIZKY RYANDHI
NRP 5213 100 112

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

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



TUGAS AKHIR - KS 141501

PENERAPAN METODE ARTIFICIAL NEURAL NETWORK (ANN) UNTUK PERAMALAN INFLASI DI INDONESIA

RIZKY RYANDHI

NRP 5213 100 112

Dosen Pembimbing :

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

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



ITS
Institut
Teknologi
Sepuluh Nopember

FINAL PROJECT - KS 141501

APPLICATION OF ARTIFICIAL NEURAL NETWORK (ANN) FOR INFLATION FORECASTING RATE IN INDONESIA

RIZKY RYANDHI

NRP 5213 100 112

Supervisor:

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

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

LEMBAR PENGESAHAN

PENERAPAN METODE ARTIFICIAL NEURAL NETWORK (ANN) UNTUK PERAMALAN INFLASI DI INDONESIA

TUGAS AKHIR

Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada

Departemen Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember

Oleh:

RIZKY RYANDHI

5213 100 112

Surabaya, 14 Juli 2017

KETUA

DEPARTEMEN SISTEM INFORMASI

Dr. Ir. Aris Tjahyanto, M. Kom.

NIP 19650310199102001



LEMBAR PERSETUJUAN

PENERAPAN METODE ARTIFICIAL NEURAL NETWORK (ANN) UNTUK PERAMALAN INFLASI DI INDONESIA

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada

Departemen Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Oleh :

Rizky Ryandhi

NRP.5213 100 112

Disetujui Tim Pengudi : Tanggal Ujian : 6 Juli 2017
Periode Wisuda : September 2017

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

(Pembimbing I)

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

(Pengudi I)

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

FAIZAL MAHANTO
(Pengudi II)

PENERAPAN METODE ARTIFICIAL NEURAL NETWORK (ANN) UNTUK PERAMALAN INFLASI DI INDONESIA

Nama : Rizky Ryandhi Pakaya
NRP : 5213 100 112
Jurusan : Sistem Informasi
Pembimbing : Edwin Riksakomara, S.Kom., M.T.
Lab : Rekayasa Data dan Intelegensi Bisnis

ABSTRAK

Nilai inflasi pada sebuah negara merupakan sebuah hal yang patut diperhatikan dan dijaga kestabilannya oleh pemerintah untuk memberikan situasi perekonomian yang kondusif. Bank Indonesia (BI) merupakan lembaga negara yang memegang tanggung jawab tersebut. BI memiliki wewenang untuk mengeluarkan kebijakan moneter dalam menjalankan fungsinya. Saat ini sebagian besar industri di Indonesia masih memiliki ketergantungan untuk mengimpor bahan baku dan bahan pendukung untuk proses produksinya. Hal tersebut menimbulkan kerentanan terjadinya inflasi di Indonesia saat negara pengimpor mengalami inflasi. Terjadinya inflasi pada negara mitra dagang mempengaruhi harga bahan baku produksi yang diimpor dari negara tersebut. Kenaikan harga produksi yang merambat ke

kenaikan harga produk, merupakan salah satu faktor penyebab terjadinya Cost-push inflation.

Penelitian ini bertujuan untuk mengembangkan model peramalan berdasarkan metode Artificial Neural Network, untuk meramalkan tingkat inflasi di Indonesia dengan memperhitungkan variable tambahan yaitu inflasi pada negara mitra dagang. Berdasarkan hasil penelitian variable inflasi pada negara mitra dagang dan nilai rupiah terhadap dollar dapat meningkatkan akurasi peramalan walaupun perbedaannya tidak terlalu signifikan.

Kata kunci : Peramalan, Inflasi, Peramalan Inflasi, Artificial Neural Network, ANN, Indonesia

*APPLICATION OF ARTIFICIAL NEURAL NETWORK
(ANN) FOR INFLATION FORECASTING IN INDONESIA*

Name : Rizky Ryandhi Pakaya

NRP : 5213 100 112

Major : Sistem Informasi

Advisor : Edwin Riksakomara, S.Kom., M.T.

Lab : Rekayasa Data dan Intelegensi Bisnis

ABSTRACT

Inflation rate in a country is something that government needs to keep an eye on to maintain its stability in order to create a conducive economic state. In Indonesia, Bank Indonesia (BI) is a legitimate state institutions holding the responsibility on that matter, since BI has the authority to issue a monetary policy. Nowadays most of Industry in Indonesia still relying on imported raw and supporting materials on their production process. That will caused Indonesia to be susceptible to inflation when the importer countries is encountering an inflation. Inflation on trading partners country may affect the price of raw and supporting materials imported from those countries. An increase of production cost that affect on an increase of the finished product prices, is one caused factor of cost-push inflation. The objective of this research is to develop a forecasting model based on artificial neural network method, to forecast the inflation rate in Indonesia while taking inflation rate in trading partner countries into account as an variable used in

the process of forecasting. Judging from the result of the research, it can be said that both variables; inflation on trading partners country and rupiah exchange rate, gives a positive effect for forecasting inflation rate resulting a higher forecasting accuracy.

KATA PENGANTAR

Pertama-tama ijinkan penulis mengucapkan puji syukur atas kehadirat Allah SWT. Karena atas rahmat-Nya penulis dapat menyelesaikan Tugas Akhir dengan judul **“Penerapan Metode Artificial Neural Network (ANN) Untuk Peramalan Inflasi di Indonesia”**. Laporan tugas akhir ini ditulis dengan tujuan untuk melengkapi persyaratan kelulusan pada Jurusan Sistem Informasi, Institut Teknologi Sepuluh Nopember.

Penulis menyadari terselesaikannya tugas akhir ini bukan hanya semata-mata kemampuan pribadi penulis, melainkan juga adanya berbagai pihak yang telah memberikan bantuan. Oleh karena itu penulis ingin mengucapkan terimakasih yang sebesar-besarnya kepada :

1. Allah SWT yang telah memberikan rahmatnya dalam memberikan kelancaran, kesehatan dan ketabahan selama penggerjaan Tugas Akhir.
2. Kedua orang tua dan keluarga yang tidak pernah berhenti mendoakan, dan memberikan segala macam dukungan, dorongan, motivasi dan semangat.
3. Bapak Dr. Ir. Aris Tjahyanto, M.Kom, selaku Ketua Jurusan Sistem Informasi ITS, yang telah menyediakan fasilitas terbaik untuk kebutuhan penelitian mahasiswa
4. Bapak Edwin Riksakomara, S.Kom., M.T. sebagai dosen wali sekaligus dosen pembimbing yang telah meluangkan banyak waktunya untuk memberikan bimbingan dan arahan dalam penggerjaan Tugas Akhir ini maupun urusan perkuliahan lainnya.

5. Para tutor, Anindita Hapsari dan Maulana Dhawangkhar yang sangat berjasa dalam membantu membangun model peramalan Artificial Neural Network.
6. Seluruh dosen dan karyawan Jurusan Sistem Informasi ITS yang telah membimbing penulis hingga terselesaikannya laporan ini.
7. Teman-teman seperjuangan Beltranis dan rekan Lab RDIB yang dapat saling memotivasi menyelesaikan Tugas Akhir.
8. Internet, Google dan ScienceDirect yang telah memberik banyak kemudahan bagi penulis dalam mencari bahan maupun jawaban yang dibutuhkan.
9. Serta seluruh pihak yang tidak dapat disebutkan satu per satu oleh penulis. Terimakasih atas dukungan dan bantuannya.

Penulis berharap laporan Tugas Akhir ini dapat bermanfaat kepada seluruh pihak yang membaca. Penulis menyadari bahwa masih banyak kekurangan dalam laporan ini, sehingga penulis berkenan menerima kritik dan saran yang dapat membangun dan memperbaiki laporan demi kesempurnaan Tugas Akhir ini.

Surabaya, 2017

Penulis

DAFTAR ISI

DAFTAR ISI	vii
DAFTAR GAMBAR	xi
DAFTAR TABEL	xiv
DAFTAR SKRIP	xv
BAB I	1
PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Perumusan Masalah.....	3
1.3. Batasan Tugas Akhir	4
1.4. Tujuan Tugas Akhir.....	4
1.5. Manfaat Tugas Akhir	5
1.6. Relevansi.....	5
BAB II.....	7
STUDI PUSTAKA	7
2.1. Penelitian Sebelumnya.....	7
2.1.1. Referensi Penelitian 1 [8].....	7
2.1.2. Referensi Penelitian 2 [9].....	8
2.2. Dasar Teori.....	9
2.2.1. Inflasi	9
2.2.2. Kurs.....	11
2.2.3. Peramalan.....	12

2.2.4.	Prosedur Peramalan	13
2.2.5.	Pola Data	14
2.2.6.	Metode Evaluasi Peramalan	16
2.2.7.	Artificial Neural Network	18
2.2.8.	Arsitektur Artificial Neural Network	19
2.2.9.	ANN Backpropagation.....	20
2.2.10.	Fungsi Pelatihan	22
2.2.11.	Fungsi Aktifasi	23
2.2.12.	Weight (W).....	25
2.2.13.	Bias (θ).....	26
2.2.14.	Epoch	26
BAB III	27	
METODOLOGI.....	27	
3.1	Diagram Metodologi.....	27
3.2	Uraian Metodologi.....	28
3.2.1	Identifikasi Permasalahan	28
3.2.2	Studi Literatur.....	28
3.2.3	Pengumpulan Raw Data.....	28
3.2.4	Pengolahan Data	29
3.2.5	Perancangan Model ANN	29
3.2.6	Peramalan inflasi dengan ANN	31
3.2.7	Analisa Hasil Peramalan	31
3.2.8	Pembuatan Aplikasi Sederhana	31
3.2.9	Penyusunan Buku Laporan Tugas Akhir.....	31

BAB IV	33
PERANCANGAN	33
4.1 Pengumpulan Data.....	33
4.2 Pengolahan Data.....	33
4.3 Pemodelan Artificial Neural Network	34
4.3.1 Pembagian Data.....	34
4.3.2 Penentuan Input	35
4.3.3 Penentuan Parameter.....	38
4.3.4 Penentuan Output.....	41
4.3.5 Pengembangan Skenario Uji Coba Model	42
4.3.6 Struktur Artificial Neural Network.....	47
4.3.7 Pengembangan Aplikasi.....	50
4.3.8 Pengembangan Interface Aplikasi	57
BAB V	59
IMPLEMENTASI.....	59
5.1 Pengolahan data.....	59
5.2 Pemodelan ANN terbaik	62
5.2.1 Pembagian Data.....	62
5.3 Pengembangan Aplikasi	67
BAB VI	71
HASIL DAN PEMBAHASAN	71
6.1 Lingkungan Uji Coba	71
6.2 Uji Penggunaan Variable.....	72
6.2.1 ModelVar1	73

6.2.2 ModelVar2	74
6.2.3 ModelVar3	76
6.2.4 ModelVar4.....	76
6.3 Uji Periode Input	79
6.3.1 Periode Peramalan 1 Bulan	79
6.3.2 Periode Peramalan 3 Bulan	81
6.3.3 Periode Peramalan 6 Bulan	83
6.3.4 Periode Peramalan 12 Bulan	86
6.4 Kesimpulan Hasil Percobaan	88
BAB VII.....	91
KESIMPULAN DAN SARAN	91
7.1 Kesimpulan	91
7.2 Saran.....	92
Daftar Pustaka	93
BIODATA PENULIS	97
LAMPIRAN A	99
LAMPIRAN B.....	131
LAMPIRAN C.....	153

DAFTAR GAMBAR

Gambar 2.1 Demand-pull Inflation	10
Gambar 2.2 Cost-push Inflation	11
Gambar 2.3 Pola data Stasioner	14
Gambar 2.4 Pola data Seasonal.....	15
Gambar 2.5 Pola Data Cyclical.....	15
Gambar 2.6 Pola Data Trend.....	16
Gambar 2.7 Jaringan Saraf Manusia VS ANN	18
Gambar 2.8 Multilayer ANN	20
Gambar 2.9 Struktur ANN.....	23
Gambar 2.10 Fungsi aktifasi linier	24
Gambar 2.11 Fungsi aktivasi sigmoid biner	24
Gambar 2.12 Fungsi aktifasi sigmoid bipolar.....	25
Gambar 3.1 Rancangan dasar ANN	30
Gambar 4.1 Struktur ANN dari Skenario 1	47
Gambar 4.2 Struktur ANN dari Skenario 2	48
Gambar 4.3 Struktur ANN dari Skenario 3	48

Gambar 4.4 Struktur ANN dari Skenario 4	49
Gambar 4.5 Struktur ANN dari Skenario 5	49
Gambar 4.0.6 Use Case Diagram	50
Gambar 5.2 Status input 1.....	68

DAFTAR BAGAN

Bagan 2.1 Algoritma Backpropagation	21
Bagan 3.1 Metodologi Pengerjaan	27

DAFTAR GRAFIK

Grafik 6.1 ModelVar1	74
Grafik 6.2 ModelVar2	75
Grafik 6.3 ModelVar4	78
Grafik 6.4 MAPE Output 1 Bulan.....	80
Grafik 6.5 MAPE Output 3 Bulan.....	83
Grafik 6.6 MAPE Output 6 Bulan.....	85
Grafik 6.7 MAPE Output 12 Bulan.....	87
Grafik 6.8 MAPE Seluruh Output.....	89

DAFTAR TABEL

Tabel 2.1 Referensi Penelitian 1	8
Tabel 2.2 Referensi Penelitian 2	8
Tabel 4.1 Variable Penelitian.....	35
Tabel 4.2 Penggunaan Variable	36
Tabel 4.3 Parameter Penelitian	40
Tabel 4.4 Skenario periode peramalan	42
Tabel 4.5 Skenario Penelitian 1	43
Tabel 4.6 Skenario Penelitian 2.....	45
Tabel 4.7 Skenario Penelitian 3.....	45
Tabel 4.8 Skenario Penelitian 4.....	46
Tabel 5.1 Data Periode 3.....	61
Tabel 6.1 LingkupUji Coba	72
Tabel 6.2 Inisialisasi Model.....	72
Tabel 6.3 Uji Korelasi	77
Tabel 6.4 MAPE Model Variable	78
Tabel 6.5 MAPE Periode Output 1	79

Tabel 6.6 MAPE Periode Output 3	81
Tabel 6.7 MAPE Periode Output 6	84
Tabel 6.8 MAPE Periode Output 12.....	86
Tabel 6.9 Kesimpulan Penggunaan Model.....	88

DAFTAR SKRIP

Skrip 5.1 Membagi Data.....	62
Skrip 5.2 Persentase Bagi Data	63
Skrip 5.3 Mengisi Data Train dan Test.....	63
Skrip 5.4 Membuat Model.....	64
Skrip 5.5 Penggunaan Parameter	64
Skrip 5.6 Inisialisasi Variable Loop	64
Skrip 5.7 Nested Looping	65
Skrip 5.8 Simulasi Model	65
Skrip 5.9 Mencari MSE Terbaik	66

(halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

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

1.1. Latar Belakang Masalah

Dalam kaca mata awam, inflasi dapat diartikan sebagai kejadian meningkatnya harga – harga barang ataupun jasa secara keseluruhan dan berkelanjutan. Dari beberapa sumber, inflasi dapat diartikan sebagai kejadian ekonomi yang sering terjadi meskipun kita tidak pernah menghendaki. Inflasi ada dimana saja dan merupakan fenomena moneter yang mencerminkan adanya pertumbuhan moneter yang berlebihan dan tidak stabil [1]. DI Indonesia, Bank Indonesia (BI) merupakan lembaga negara yang memegang tanggung jawab terhadap permasalahan tersebut. BI memiliki wewenang untuk mengeluarkan kebijakan moneter untuk mengatur kegiatan bisnis di dalam negara dan menjaga kestabilan nilai rupiah.

Sampai saat ini secara terus menerus pakar ekonomi berusaha memahami faktor yang dapat menyebabkan terjadinya inflasi. Saat ini para ahli ekonomi menyetujui untuk membedakan jenis penyebab inflasi menjadi dua, yaitu *Demand-pull Inflation* dan *Cost-Push Inflation*. *Demand-pull Inflation* terjadi saat terjadinya lonjakan permintaan yang besar dari masyarakat terhadap sebuah barang atau jasa, namun tidak diimbangi dengan ketersediaan barang atau jasa yang dibutuhkan tersebut. Sedangkan *Cost-push*

Inflation disebabkan oleh kenaikan biaya produksi, kejadian ini biasa disebabkan oleh kenaikan harga bahan mentah yang dibutuhkan untuk proses produksi oleh industri [2].

Saat ini sebagian besar industri di Indonesia masih belum mampu mandiri dalam menyediakan sendiri bahan mentah yang diperlukan untuk proses produksi. Sekitar 64% bahan baku, bahan penolong dan barang modal yang digunakan oleh industri di Indonesia masih diimpor [3]. Kebutuhan impor tersebut terjadi pada hampir setiap sektor Industri di Indonesia seperti perminyakan, makanan, elektronik, kendaraan, dan sektor industry lainnya [4]. Negara-negara seperti Saudi Arabia, Thailand, Vietnam, Jepang, Cina dan Australia merupakan beberapa negara importir terbesar ke Indonesia untuk sektor-sektor industri utama Indonesia [5].

Ketergantungan industri Indonesia terhadap barang mentah impor menjadikan Indonesia rentan terhadap inflasi, apabila negara mitra dagang tersebut mengalami inflasi. Sebab saat negara mitra dagang mengalami inflasi, seluruh harga pada negara tersebut akan naik, termasuk barang mentah yang dibutuhkan untuk diimpor ke Indonesia. Dengan adanya kenaikan harga pada barang impor, akan menaikkan biaya pada proses produksi barang, hal inilah yang menjadi penyebab terjadinya *Cost-push Inflation* di Indonesia.

Inflasi juga sangat dekat hubungannya dengan nilai tukar rupiah. Saat terjadi kenaikan inflasi, nilai tukar rupiah akan terdepresiasi terhadap dollar AS, dimana nilai rupiah yang dibutuhkan untuk mendapatkan satu dollar AS akan meningkat. Penurunan nilai tukar rupiah mempengaruhi daya beli industri untuk mengimpor bahan baku atau bahan mentah.[6]

Atas dasar tersebut penelitian ini dilakukan, penelitian ini berusaha melakukan peramalan inflasi di Indonesia dengan menggunakan metode *Artificial Neural Network* (ANN), dengan memperhitungkan variable tambahan yaitu :

- Tingkat inflasi pada negara yang memiliki hubungan kerjasama dagang dengan Indonesia.
- Nilai impor bahan mentah untuk industri Indonesia
- Nilai rupiah terhadap dollar

Pemilihan metode peramalan menggunakan metode ANN dilakukan berdasarkan penelitian sebelumnya yang menyatakan ANN memberikan peramalan dengan tingkat *error* yang rendah untuk studi kasus inflasi. Penelitian ini bertujuan untuk mengembangkan model peramalan berdasarkan metode Artificial Neural Network, untuk meramalkan tingkat inflasi di Indonesia dengan memperhitungkan variable tambahan yaitu inflasi pada negara mitra dagang. Dengan hasil peramalan yang dihasilkan dari penelitian ini, diharapkan dapat memberikan wawasan bagi pemerintah, khususnya Bank Indonesia, dalam membantu pengambilan keputusan penentuan kebijakan moneter untuk menghindari kemungkinan terjadinya inflasi.

1.2. Perumusan Masalah

Perumusan masalah yang diangkat pada tugas akhir ini adalah:

- a. Bagaimana pemodelan dan penerapan *Artificial Neural Network* untuk meramalkan tingkat inflasi di Indonesia dilakukan?
- b. Bagaimana tingkat akurasi peramalan inflasi di Indonesia menggunakan metode ANN?

- c. Bagaimana pengaruh variable nilai tukar rupiah, tingkat inflasi negara mitra dagang dan kegiatan impor bahan baku industry terhadap hasil peramalan?

1.3. Batasan Tugas Akhir

Batasan pemasalahan dalam tugas akhir ini adalah :

- a. Pada penelitian berfokus pada penggunaan metode *Artificial Neural Network* (ANN) untuk meramalkan inflasi di Indonesia pada tahun 2017
- b. Peramalan dilakukan menggunakan variable tingkat inflasi di Indonesia dengan pengaruh variable nilai tukar rupiah terhadap dollar, juga tingkat inflasi negara mitra dagang dan kegiatan impor bahan baku industri di Indonesia sebagai faktor *cost-pull* penyebab inflasi.
- c. Data inflasi yang digunakan merupakan data sekunder yang dikutip dari www.gdpinflation.com [7] dengan periode bulanan pada bulan Januari 1995 sampai dengan Januari 2017.
- d. Data kegiatan expor - impor dan nilai rupiah terhadap dolar merupakan data sekunder yang dikutip dari Badan Pusat Statistik Indonesia dengan periode bulanan pada bulan Januari 1995 sampai dengan Januari 2017.
- e. Peramalan dilakukan menggunakan aplikasi MATLAB

1.4. Tujuan Tugas Akhir

Tujuan dari penggeraan tugas akhir ini adalah :

- a. Menerapkan Model ANN untuk meramalkan tingkat inflasi di Indonesia pada tahun 2017
- b. Mengetahui akurasi dari hasil peralaman menggunakan ANN

- c. Mengetahui pengaruh variable tambahan terhadap hasil peramalan

1.5. Manfaat Tugas Akhir

Berdasarkan tujuan dari penelitian ini yaitu meramalkan tingkat inflasi di Indonesia dan menguji pengaruh variable terhadap hasil peramalan. Penelitian ini memberikan hasil peramalan yang diharapkan dapat memberikan gambaran nilai inflasi kepada pemerintah untuk beberapa bulan – bulan kedepan. Hasil peramalan dengan pengaruh variable yang telah disebutkan sendiri diharapkan dapat memberi pengetahuan kepada pembaca mengenai apakah variable tersebut baik digunakan dan dapat meningkatkan akurasi peramalan inflasi atau tidak.

1.6. Relevansi

Penelitian ini dilakukan terkait dengan penyelesaian Tugas Akhir dengan topik peramalan. Peramalan sendiri merupakan topik bahasan pada Laboratorium Rekayasa Data dan Inteligensi Bisnis (RDIB). Metode peramalan yang digunakan pada penelitian ini adalah *Artificial Neural Network*. Materi mengenai metode peramalan yang digunakan didapatkan dari perkuliahan pada matakuliah Teknik Peramalan dan Sistem Cerdas.

(halaman ini sengaja dikosongkan)

BAB II

STUDI PUSTAKA

Dalam bab ini akan menjelaskan mengenai penelitian sebelumnya dan dasar teori yang akan dijadikan acuan atau landasan dalam pengerjaan tugas akhir ini.

2.1. Penelitian Sebelumnya

Beberapa penelitian sebelumnya yang dijadikan acuan dalam pengerjaan tugas akhir disajikan dalam tabel berikut

2.1.1. Referensi Penelitian 1 [8]

Judul Paper	Aplikasi Metode Ensemel untuk Peramalan Inflasi di Indonesia
Penulis; Tahun	Mega Sifiani, Suhartono; Maret 2013
Deskripsi Umum Penelitian	Penelitian ini melakukan peramalan tingkat inflasi di Indonesia dan beberapa kota di Jawa Timur untuk periode tahun 2013. Penelitian ini menggunakan metode ensemble untuk meramalkan inflasi. Perbandingan hasil peramalan dilakukan pada metode ARIMA, ARIMA Ensambel (ARIMAX), Single ANN, ANN Ensemel, dan ANN-ARIMA Ensemble. Hasil akhir menunjukkan bahwa Single ANN memberikan RMSE terkecil.

Keterkaitan Penelitian	Penelitian ini menggunakan model ANN dalam melakukan peramalan dengan membandingkan model tersebut dengan ARIMA dan Ensemble kedua model. Setelah mendapat hasil peramalan dengan ANN sebagai model dengan nilai error terkecil, penelitian ini dapat dijadikan sebagai acuan dalam melakukan penelitian.
-------------------------------	---

Tabel 2.1 Referensi Penelitian 1

2.1.2. Referensi Penelitian 2 [9]

Judul Paper	Inflation forecasting using a neural network
Penulis; Tahun	Nakamura Emi; 2005
Deskripsi Umum Penelitian	Paper ini melakukan evaluasi terhadap kegunaan <i>neural network</i> untuk meramalkan inflasi. Hasil penelitian menemukan bahwa ANN memberikan performa yang buruk dalam meramalkan kegiatan makroekonomi dengan model linear. Namun pada peramalan inflasi, ANN memberikan performa yang baik pada model <i>autoregressive</i> untuk peramalan dua sampai tiga kuarter kedepan.
Keterkaitan Penelitian	Paper ini mengevaluasi ANN dalam meramalkan inflasi. Mendapati hasil performa ANN yang baik digunakan untuk peramalan sejauh dua sampai tiga kuarter menjadi bahan pertimbangan pada penelitian ini

Tabel 2.2 Referensi Penelitian 2

2.2. Dasar Teori

Berisi teori-teori yang mendukung serta berkaitan dengan tugas akhir yang sedang dikerjakan.

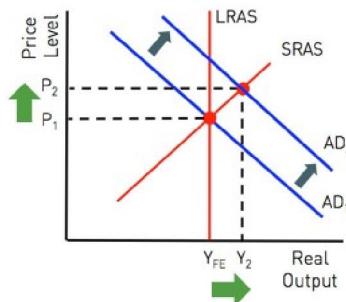
2.2.1. Inflasi

Inflasi dapat diartikan sebagai kejadian meningkatnya harga – harga barang ataupun jasa secara keseluruhan dan berkelanjutan. Dari beberapa sumber, inflasi dapat diartikan sebagai kejadian ekonomi yang sering terjadi meskipun kita tidak pernah menghendaki. Inflasi ada dimana saja dan selalu merupakan fenomena moneter yang mencerminkan adanya pertumbuhan moneter yang berlebihan dan tidak stabil [1]. Pendapat ahli lain mengemukakan bahwa definisi inflasi adalah kecenderungan kenaikan harga secara umum dan terus menerus. Kenaikan harga pada satu atau dua barang saja tidak bias disebut inflasi, kenaikan harga dapat dikatakan sebagai inflasi jika kenaikan tersebut meluas ke epada sebagian besar harga lainnya. Syarat adanya kecenderungan kenaikan secara terus menerus juga perlu menjadi perhatian [10], pendapat ahli lain juga menyatakan bahwa inflasi merupakan suatu kejadian yang menunjukkan kenaikan tingkat harga secara umum dan berlangsung secara terus menerus [11].

Penyebab inflasi dibedakan menjadi dua jenis, yaitu *Demand-pull inflation* dan *Cost-push Inflation*.

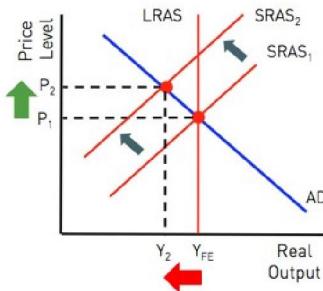
- a. *Demand-pull inflation* merupakan penyebab inflasi yang diakibatkan oleh terjadinya lonjakan permintaan terhadap barang atau jasa yang tidak diseimbangi dengan persediaan (supply) barang atau jasa yang dibutuhkan tersebut. Saat lonjakan permintaan tersebut terjadi, maka akan terjadi peningkatan permintaan terhadap produksi. Meningkatnya

permintaan produksi akan menyebabkan harga faktor produksi meningkat. Pada saat seperti ini peningkatan harga dapat meluas ke aspek lainnya, maka terciptalah inflasi. [12]



Gambar 2.1 Demand-pull Inflation

- b. *Cost-push inflation* merupakan penyebab inflasi yang disebabkan oleh meningkatnya biaya proses produksi. Meningkatnya biaya proses produksi utamanya disebabkan oleh naiknya harga bahan produksi (input), sehingga mengakibatkan produk (output) turut mengalami kenaikan harga. Kenaikan harga bahan produksi menaikkan tidak hanya satu dua produsen melainkan keseluruhan industri terkait bahan tersebut, maka terjadilah inflasi. [12]



Gambar 2.2 Cost-push Inflation

Berdasarkan parah atau tidaknya inflasi pada sebuah negara dapat digolongkan pada *range* nilai berikut :

1. Inflasi ringan; dibawah 10% setahun
2. Inflasi sedang; antara 10% - 30% setahun
3. Inflasi berat; antara 30% - 100% setahun
4. Inflasi hiper; diatas 100% setahun

2.2.2. Kurs

Kurs valuta atau valuta asing, atau biasa dikenal juga dengan istilah *exchange rate* merupakan tingkat harga yang disepakati kedua negara untuk saling melakukan perdagangan [13]. Sehingga kurs ini biasa dikaitkan dengan nilai tukar mata uang suatu negara dengan negara lainnya. Karena pada era modern ini mata uang merupakan alat pembayaran dan kesatuan hitung dalam transaksi ekonomi dan keuangan internasional, maka mata uang tersebut disebut sebagai *hard currency*. Dimana mata uang ini nilainya terbilang stabil, namun terkadang dapat mengalami apresiasi

atau kenaikan nilai dibandingkan dengan mata uang negara lainnya. Kenaikan nilai mata uang atau apresiasi ini yang menjadikan nilai jual beli mata uang suatu negara ke negara lainnya akan terus berubah – ubah.

2.2.3. Peramalan

Peralaman merupakan sebuah kegiatan untuk membuat perkiraan atau prediksi mengenai apa yang akan terjadi di masa yang akan datang. Peramalan dilakukan untuk melakukan perkiraan atau prediksi dengan waktu yang relative lama. Sedangkan arti dari ralaman adalah suatu kondisi atau situasi yang diperikirakan atau diprediksi akan terjadi pada masa yang akan datang. Menurut ahli Barry Render dan Jay Heizer, peramalan (forecasting) dapat diartikan sebagai seni dan ilmu memprediksi peristiwa-peristiwa masa depan dengan pengambilan data historis dan memproyeksikannya ke masa depan menggunakan beberapa bentuk model matematis.

Peramalan dapat dikatakan penting untuk membantu pengambilan keputusan, ada beberapa faktor yang bisa menyebabkan efektif atau tidaknya suatu keputusan , yaitu faktor-faktor yang tidak kita lihat ketika keputusan itu diambil[14]. Peramalan juga bisa digunakan dalam aktivitas bisnis dimana bisa memperkirakan jumlah penjualan dan penggunaan produk di periode yang akan datang ,sehingga produk dapat dibuat dalam kuantitas yang tepat sesuai dengan hasil peramalan. Peramalan merupakan perkiraan dari permintaan yang akan datang berdasarkan pada beberapa variabel peramal yang diberdasarkan pada data history.

Dalam peramalan, untuk mendapatkan hasil yang akurat dan bermanfaat, terdapat dua hal yang harus diperhatikan [15]:

1. Data yang dikumpulkan haruslah berupa informasi yang relevan sehingga dapat menghasilkan peramalan yang akurat.
2. Penggunaan metode peramalan yang tepat.

2.2.4. Prosedur Peramalan

Dalam melakukan peramalan terdapat langkah-langkah atau prosedur yang harus dilakukan untuk mendapatkan hasil peralaman yang baik. Pada dasarnya terdapat tiga langkah utama dalam melakukan peramalan yaitu :

1. Pertama adalah melakukan analisa terhadap data masa lalu. Dalam melakukan peramalan tentunya peneliti memerlukan data masa lalu. Pada tahap ini berguna untuk menganalisa pola kejadian di masa lalu yang dilihat dari data. Analisis ini dilakukan dengan cara membuat tabulasi dari data masa lalu. Dengan mengetahui pola data, akan membantu dalam penentuan metode peramalan yang akan dipilih untuk memberikan hasil peramalan yang baik, dan sesuai dengan pola kejadian sebelumnya.
2. Langkah selanjutnya, setelah mengetahui pola data yang akan digunakan, adalah menentukan metode yang akan digunakan dalam melakukan peramalan. Metode peramalan yang baik akan memberikan hasil peralaman yang baik, dimana hasil peramalan tersebut tidak jauh dengan kenyataan yang terjadi.
3. Ketiga dan yang terakhir adalah memproyeksikan data masa lalu dengan menggunakan metode yang dipergunakan dan mempertimbangkan adanya beberapa faktor yang memberikan pengaruh.

2.2.5. Pola Data

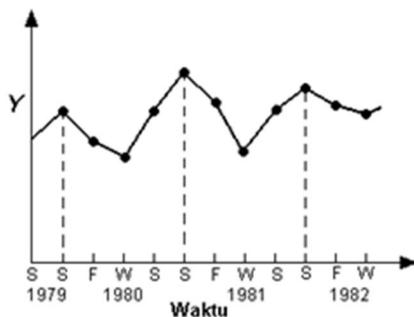
Pada langkah – langkah permalan disebutkan bahwa langkah pertama adalah menganalisa pola kejadian masa lalu. Pola kejadian masa lalu tersebut akan tergambar pada pola data. Terdapat empat jenis pola data yang dapat digunakan untuk melakukan peramalan yaitu :

1. Pola Horizontal atau stationary, pola ini terbentuk ketika data berfluktasi di sekitar rata-ratanya. Jika digambarkan menggunakan grafik garis, maka pola yang dibuat terbentuk hampir seperti garis lurus pada rata - ratanya



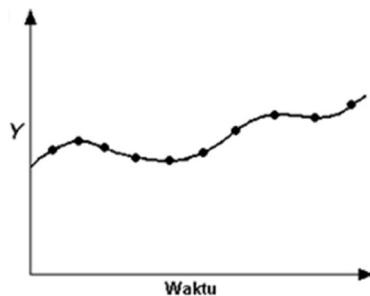
Gambar 2.3 Pola data Stasioner

2. Pola Musiman atau Seasonal, pola ini terbentuk jika suatu deret waktu dipengaruhi oleh faktor musim seperti kuartalan, bulanan, mingguan atau harian. Faktor musim ini mempengaruhi jumlah data seperti contoh penjualan minuman segar yang terlihat meningkat di setiap bulan musim panas, atau jumlah penjualan pakaian yang meningkat pada setiap menjelang hari raya



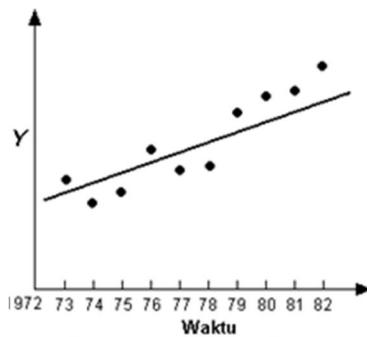
Gambar 2.4 Pola data Seasonal

3. Pola Siklus atau Cyclical, pola ini terbentuk apabila data dipengaruhi fluktiasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis



Gambar 2.5 Pola Data Cyclical

4. Pola Trend, pola ini terbentuk jika ada pertambahan atau kenaikan atau penurunan dari data observasi untuk jangka panjang



Gambar 2.6 Pola Data Trend

Selain yang sudah disebutkan diatas, terdapat satu lagi pola data yang tidak dapat digunakan untuk melakukan peramalan. Adalah Pola Acak, apabila fluktuasi data jangka panjang tidak dapat digambarkan oleh keempat pola data lainnya. Fluktuasi ini bersifat acak atau tidak jelas, sehingga tidak ada metode peramalan yang direkomendasikan untuk pola ini.

2.2.6. Metode Evaluasi Peramalan

Untuk mengetahui keakuratan hasil peramalan dilakukan evaluasi, terdapat beberapa teknik atau metode yang dapat digunakan untuk melakukan evaluasi atau validasi metode peramalan. Pada penelitian ini Mean Squared Error dan Mean Absolute Percentage Error adalah metode yang digunakan untuk mengevaluasi hasil peramalan.

1. Mean Squared Error (MSE)

Mean Squared Error (MSE) merupakan metode perhitungan error dengan mengkuadratkan nilai error pada tiap periode. Dalam kasus pencarian model ANN, dengan nilai MSE yang lebih kecil,

mengindikasikan model yang lebih stabil [16]. MSE dapat dihitung dengan rumus berikut :

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y'i - Yi)^2$$

Keterangan :

n = Jumlah Sampel

Y' = Nilai actual indeks

Y = Nilai prediksi

2. Mean Absolute Precentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan metode yang menghitung kesalahan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, merata-rata kesalahan persentase absolut tersebut. MAPE memiliki kemampuan yang lebih baik dari MSE dalam menghitung error. MAPE dapat dihitung dengan menggunakan rumus berikut :

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{xt - ft}{xt} \right|}{n} \times 100\%$$

Keterangan :

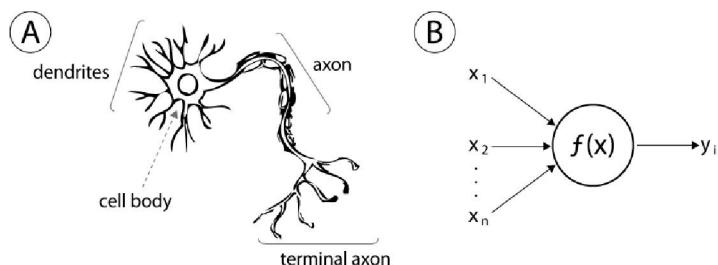
n = Jumlah Sampel

xt = Nilai Aktual Indeks pada period ke-t

ft = Nilai Prediksi Indeks pada period ke-t

2.2.7. Artificial Neural Network

Artificial Neural Network (ANN) merupakan sebuah sistem cerdas yang digunakan untuk mengolah informasi yang merupakan perkembangan dari generalisasi model matematika. Prinsip kerja ANN terinspirasi dari prinsip kerja sistem jaringan saraf (*neural network*) manusia [17]. Para ilmuan menciptakan algoritma matematis yang bekerja menyerupai pola kerja saraf (neuron) tersebut, maka digunakanlah nama *Artificial Neural Network*, atau dalam Bahasa Indonesia biasa disebut Jaringan Saraf Tiruan (JST). Gambar dibawah menggambarkan kemiripan arsitektur ANN dengan dengan sistem jaringan saraf pada tubuh manusia :



Gambar 2.7 Jaringan Saraf Manusia VS ANN

Label A pada gambar diatas merupakan struktur susunan sel neuron pada tubuh manusia. Sel neuron berfungsi sebagai pengantar informasi dari satu sel, ke sel lainnya dengan urutan sebagai berikut :

- Dendrit merupakan bagian yang berfungsi untuk menerima rangsangan atau informasi
- Badan sel bertugas menerima dan mengakumulasikan rangsangan dari dendrit, memproses informasi tersebut dan lalu meneruskannya ke akson

- Akson berfungsi meneruskan rangsangan yang telah diproses badan sel ke neuron lain.

Label B menggambarkan struktur ANN, dimana juga terdapat tiga bagian didalamnya yaitu *input layer* (x), *hidden layer* ($f(x)$) dan *output layer* (y). Informasi akan diterima oleh *input layer* menggunakan bobot yang ditentukan. Bobot akan dikumpulkan dan diakumulasikan oleh *hidden layer*. Kemudian hasil penjumlahan tersebut dibandingkan dengan *threshold* yang ditentukan sebagai nilai aktifasi. Informasi yang masuk memenuhi syarat akan dilanjutkan ke *output layer* [18].

2.2.8. Arsitektur *Artificial Neural Network*

Pada ANN, neuron diasumsikan dapat dikelompokkan dalam *layer* seperti yang telah dijelaskan sebelumnya. Berdasarkan jumlah *hidden layer* yang digunakan pada ANN, struktur ANN dibagi menjadi dua yaitu *single layer network* dan *multilayer network*.

1. Jaringan lapis tunggal (*single layer network*)
Jaringan lapis tunggal terdiri dari satu *layer* dari bobot yang saling terhubung. Pada jaringan lapis tunggal, informasi yang masuk akan langsung diproses menjadi sinyal keluaran tanpa melalui *hidden layer* terlebih dahulu. Label B pada **gambar 2.7** merupakan contoh dari bentuk ANN *single layer*.
2. Jaringan lapis jamak (*multilayer network*)
ANN dengan tipe ini memiliki lebih dari satu *layer* yang diberi nama *hidden layer*. Semua layer yang terletak diantara *input layer* dan *output layer* merupakan *hidden layer*, karena jumlah *hidden layer* yang bisa lebih dari satu *layer*. ANN lapis jamak ini menggunakan fungsi aktivasi *nonlinear* yang dapat digunakan untuk menyelesaikan berbagai tipe

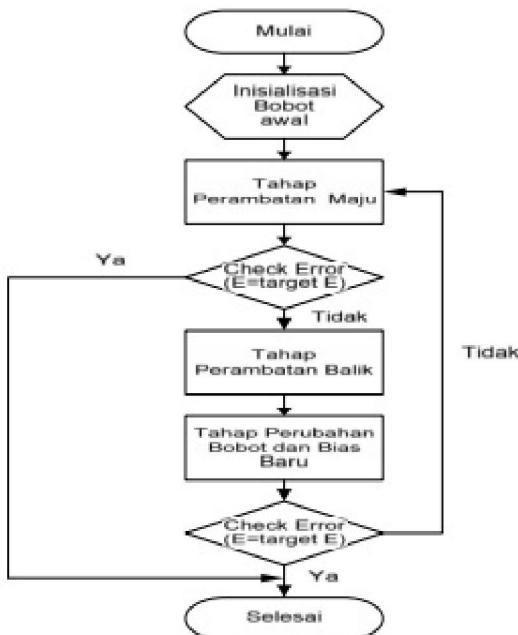
permasalahan yang lebih rumit dan kompleks. Arsitektur *multilayer network* dapat dilihat pada **gambar 2.8** di bawah.



Gambar 2.8 Multilayer ANN

2.2.9. ANN Backpropagation

Backpropagation merupakan sebuah algoritma pembelajaran dalam *Artificial Neural Network* yang telah banyak digunakan untuk memecahkan kasus-kasus rumit. Algoritma ini telah ada sejak tahun 1970an namun mulai dikenal kalangan luas semenjak dikenalkan oleh David Rumelhart, Geoffrey Hinton dan Ronald Williams pada papernya pada tahun 1986 [19]. Di dalam algoritma ini dilakukan dua tahap perhitungan, yaitu perhitungan maju yang dilakukan untuk menghitung error antara output ANN dengan target yang diinginkan. Dan yang berikutnya adalah perhitungan mundur yang menggunakan error yang telah didapatkan untuk memberbaiki bobot pada semua neuron yang ada. **Bagan 2.1** di bawah menjelaskan alur kerja dari algoritma backpropagation.



Bagan 2.1 Algoritma Backpropagation

Terdapat tiga fase utama dalam alur kerja backpropagation, yaitu fase 1. *feed forward*, 2. *backpropagation error*, dan yang terakhir adalah 3. Perubahan nilai bobot. Berikut penjabaran dari masing-masing fase:

1. *Feedforward*

Tahap ini merupakan alur maju dari penggunaan artificial neural network seperti biasanya, dimana semua nilai input dan variable yang digunakan pada input layer dikirimkan ke *hidden layer*. Nilai tersebut diterima oleh sejumlah node yang ditentukan pada *hidden layer* lalu dihitung

menggunakan fungsi aktivasi. Hasil perhitungan dari masing-masing node di *hidden layer* tersebut diberikan bobot yang selanjutnya dikirim ke *output layer*. Pada *output layer* ini kembali dilakukan perhitungan menggunakan fungsi aktivasi tertentu, untuk menghasilkan nilai output berdasarkan pola masukan.

2. *Backpropagation error*

Backpropagation error dilakukan setelah *neural network* berhasil memberikan output dari perhitungan input seperti yang telah dijelaskan pada proses *feedforward*. Nilai yang didapatkan oleh masing-masing *output node* dibandingkan dengan nilai *output* yang diinginkan menggunakan fungsi loss, menghitung nilai *error* pada setiap node. Selanjutnya nilai error yang didapatkan dipropagasi ke belakang, dimulai dari output, sehingga semua node baik di *output* maupun *hidden layer* memberikan gambaran nilai error terhadap nilai output yang diinginkan.

3. Perubahan nilai bobot

Setelah mendapatkan nilai error, selanjutnya nilai error digunakan untuk menghitung gradien dari loss function dengan memperhatikan bobot dari network. Selanjutnya gradien tersebut digunakan untuk mendapatkan nilai optimal yang selanjutnya digunakan untuk memperbarui nilai bobot.

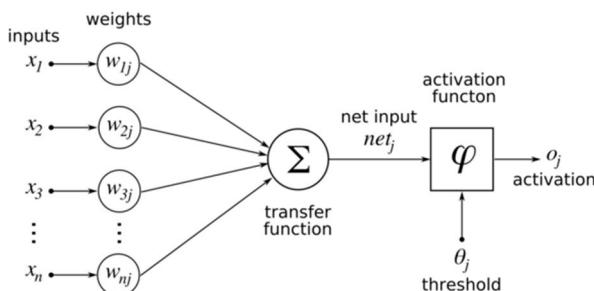
2.2.10. Fungsi Pelatihan

Fokus utama dalam peramalan menggunakan metode ANN adalah untuk melatih network untuk dapat memahami pattern nilai yang dimiliki dari sebuah kasus berdasarkan data historis untuk dapat memprediksi nilai yang akan datang. Fungsi pelatihan berfungsi sebagai algoritma yang digunakan pada ANN untuk melatih

network dalam memahami pattern tersebut. Terdapat banyak fungsi pelatihan yang tersedia dan dapat digunakan, hal ini menjadikan sebagian orang bingung untuk menentukan fungsi pelatihan apa yang paling baik untuk digunakan. Namun berdasarkan uji coba yang dilakukan MATLAB didapatkan dua fungsi pelatihan yang dipilih dalam penelitian ini. Kedua fungsi tersebut adalah Lavenberg-Marquardt (LM), BFGS Quasi-Newton (BFG) [20]. Kedua fungsi pelatihan diatas telah diuji dan dibuktikan lebih baik dari fungsi lainnya oleh MATLAB dalam memecahkan kasus dengan tipe permasalahan baik *function approximation* maupun *pattern recognition*.

2.2.11. Fungsi Aktifasi

Fungsi aktivasi merupakan fungsi yang digunakan untuk mengolah inputan informasi. Sebagai gambaran, fungsi aktivasi dapat dilihat pada **gambar 2.9** di bawah ini.

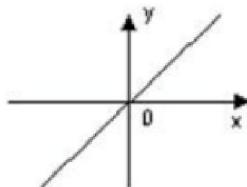


Gambar 2.9 Struktur ANN

Dapat dilihat pada struktur ANN diatas, fungsi transfer berfungsi mengubah sejumlah inputan ($x_1, x_2, x_3 \dots x_n$) yang memiliki bobot ($W_{1j}, W_{2j}, \dots, W_{nj}$) dan bias menjadi nilai input (net_j) bagi fungsi aktivasi. Selanjutnya fungsi aktivasi memproses nilai input untuk dibandingkan dengan *threshold* yang ditentukan dan mengaktifasi

nilai menjadi output (o_j). Beberapa fungsi aktivasi yang digunakan pada ANN adalah :

1. Fungsi aktifasi linier

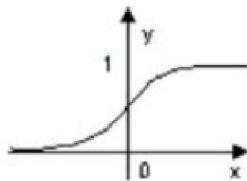


Gambar 2.10 Fungsi aktifasi linier

Fungsi aktivasi linier menghasilkan nilai output yang sama dengan nilai input. Fungsi aktivasi linear dapat digunakan dengan rumus :

$$f(x) = x$$

2. Fungsi aktivasi sigmoid biner

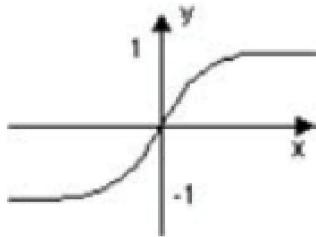


Gambar 2.11 Fungsi aktivasi sigmoid biner

Fungsi aktivasi sigmoid biner menghasilkan nilai output pada interval 0 hingga 1. Rumus fungsi ini adalah :

$$y = ft(x) = \frac{1}{1 + \exp(-x)}$$

3. Fungsi aktivasi sigmoid bipolar



Gambar 2.12 Fungsi aktifasi sigmoid bipolar

Fungsi aktivasi sigmoid bipolar menghasilkan nilai output pada interval -1 hingga 1. Fungsi aktivasi sigmoid bipolar dapat digunakan dengan rumus :

$$y = ft(x) = \frac{2}{1 + \exp(-x)} - 1$$

2.2.12. *Weight (W)*

Bobot pada ANN memiliki fungsi sebagai penghubung antar *layer* dan mengalikan nilai yang diterima dari input. Bobot dapat diatur sedemikian rupa untuk memberikan output yang dikehendaki dari nilai input tertentu. Dalam meneginisiasi nilai awal bobot dapat dilakukan secara random pada rentang nilai -1 sampai 1, atau -0,5 sampai 0,5.

Bobot juga dapat ditentukan menggunakan rumus :

$$W = \left(-\frac{2.4}{F_i}, +\frac{2.4}{F_i} \right)$$

Dimana F_i adalah nilai total variabel / *node* pada *input layer*. [21]

2.2.13. Bias (θ)

Bias merupakan nilai ketidak pastian pada suatu node dalam *layer*. Bias diberikan untuk setiap *node* pada *hidden layer*. Untuk menentukan nilai inisiasi bias dapat menggunakan rumus :

$$\theta = \left(-\frac{2.4}{F_i}, +\frac{2.4}{F_i} \right)$$

Dimana F_i adalah nilai total *node* pada *hidden layer*. [21]

2.2.14. Epoch

Epoch merupakan jumlah pengulangan atau iterasi yang dilakukan terhadap pola hingga mendapatkan nilai error yang ditentukan atau sampai jumlah pengulangan epoch yang ditentukan.

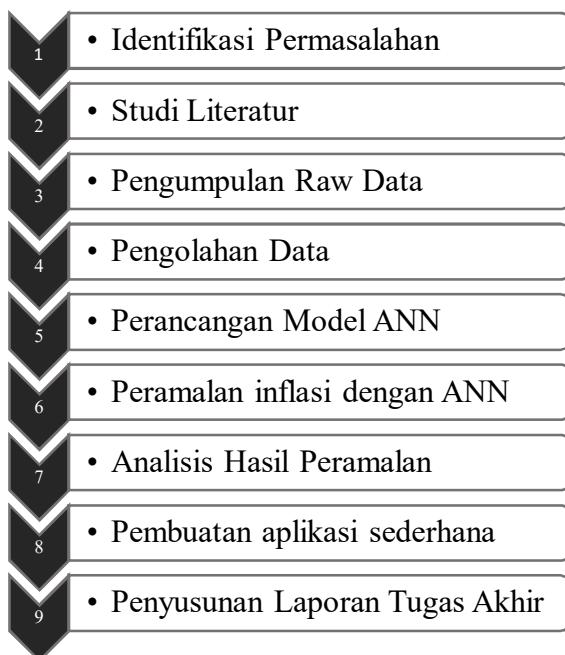
BAB III

METODOLOGI

Pada bab ini membahas mengenai apa saja yang anak dilakukan dalam menyelesaikan tugas akhir disertai dengan penjabaran masing – masing langkah pengerjaan dan penjadwalan pengerjaan.

3.1 Diagram Metodologi

Berikut merupakan alur metodologi untuk tugas akhir menggunakan metode *ANN*:



Bagan 3.1 Metodologi Pengerjaan

3.2 Uraian Metodologi

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

3.2.1 Identifikasi Permasalahan

Pada tahap ini dilakukan identifikasi permasalahan yang akan dijadikan objek penelitian. Yang dimaksud dengan identifikasi permasalahan adalah menentukan permasalahan apa yang akan diangkat dalam penelitian, lalu dilakukan perumusan terhadap masalah yang dihadapi untuk menentukan tujuan, manfaat dan batasan dari penelitian.

3.2.2 Studi Literatur

Pada tahap ini dilakukan pendalaman pemahaman mengenai segala informasi yang berhubungan dengan permasalahan dan penelitian yang akan dilakukan dengan mencari sumber – sumber pendukung. Sumber yang digunakan dapat berupa buku, paper ilmiah, jurnal, laporan hasil penelitian dan berbagai macam sumber lainnya yang dapat dipercaya. Studi literatur diperlukan untuk memahami dasar teori terkait objek penelitian. Beberapa hal yang dipelajari terkait penelitian ini diantaranya adalah mengenai Inflasi, ANN, Peramalan dan MATLAB.

3.2.3 Pengumpulan Raw Data

Pada tahapan pertama ditentukan variable apa saja yang akan digunakan untuk melakukan peramalan. Selanjutnya data dari variable yang akan digunakan dalam melaksanakan penelitian tersebut dikumpulkan. Data yang digunakan pada penelitian ini adalah :

- Data historis tingkat inflasi pada negara Indonesia dan negara mitra dagang Indonesia. Data yang digunakan pada penelitian ini merupakan data sekunder yang dikutip dari www.gdpinflation.com [7]
- Data historis kegiatan impor bahan baku industri di Indonesia yang dikutip dari website resmi Badan Pusat Statistik Indonesia.
- Data historis nilai tukar rupiah terhadap dollar yang dikutip dari website Investing.com

3.2.4 Pengolahan Data

Pada tahap ini raw data yang telah didapatkan diolah untuk dianalisis. Hasil analisis data akan memberikan pemahaman terhadap pola data. Pemahaman terhadap pola data digunakan sebagai dasar pemilihan metode peramalan. Peneliti juga melakukan penataulangan data untuk mempermudah penggunaan data saat melakukan peramalan dengan MATLAB. Data akan dipisahkan berdasarkan fungsinya, 70% data digunakan sebagai data *training*, sedangkan 30% lainnya digunakan sebagai data uji akurasi peramalan.

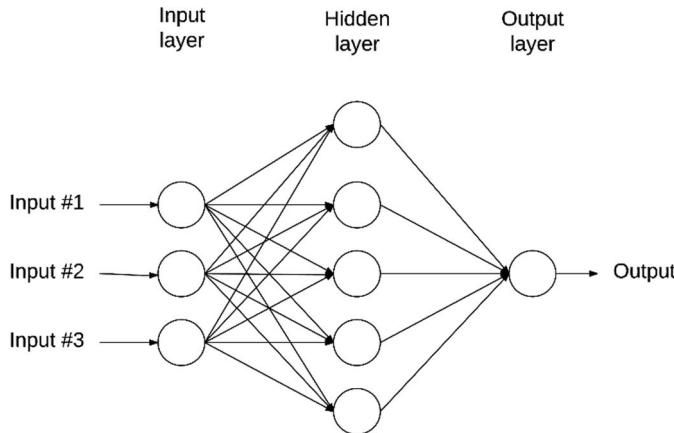
3.2.5 Perancangan Model ANN

Pada tahap ini dilakukan perancangan model ANN dengan menentukan :

1. Penentuan struktur ANN seperti *input layer*, *hidden layer* dan *output layer*.
2. Menentukan Bobot dan Bias ANN
3. Menentukan nilai laju pembelajaran
4. Menentukan koefisien momentum dan epoch
5. Menentukan *threshold* atau fungsi aktivasi sebagai fungsi pemroses input menjadi output.

6. Melakukan verifikasi dan validasi rancangan model

Berikut merupakan rancangan dasar bentuk model ANN yang akan digunakan untuk meramalkan tingkat inflasi di Indonesia.



Gambar 3.1 Rancangan dasar ANN

Input layer : input layer berisikan nilai dari variable-variable yang digunakan pada peramalan. Dimana variable yang digunakan adalah tingkat inflasi di Indonesia, tingkat inflasi pada negara mitra dagang, nilai impor bahan baku industry dan nilai rupiah terhadap dollar.

Hidden layer : hidden layer merupakan lapisan yang menghubungkan *input layer* dengan *output layer*, pada *hidden layer* nilai input dipengaruhi dengan nilai bias.

Output layer : pada output layer dihasilkan hasil peramalan akhir yaitu tingkat inflasi di Indonesia.

3.2.6 Peramalan inflasi dengan ANN

Pada tahap ini dilakukan tujuan utama dari penelitian yaitu melakukan peramalan inflasi di Indonesia menggunakan model ANN yang sebelumnya telah dirancang. Proses peramalan dibantu dengan aplikasi MATLAB yang berfungsi sebagai pengolah data.

3.2.7 Analisa Hasil Peramalan

Tahapan ini untuk menguji tingkat keakuratan dari hasil peramalan dengan melihat nilai MAPE, yaitu dengan membandingkan hasil peramalan dengan data aktual sehingga akan didapatkan keakuratan dari hasil peramalan.

3.2.8 Pembuatan Aplikasi Sederhana

Pada tahap ini dilakukan pembuatan aplikasi sederhana agar peramalan dapat dilakukan oleh pengguna dengan lebih mudah tanpa perlu menggunakan aplikasi MATLAB. Aplikasi dilengkapi dengan grafik, untuk membantu meningkatkan pemahaman pengguna terhadap hasil peramalan.

3.2.9 Penyusunan Buku Laporan Tugas Akhir

Tahapan terakhir adalah pembuatan laporan tugas akhir sebagai bentuk dokumentasi atas terlaksananya tugas akhir ini

(halaman ini sengaja dikosongkan)

BAB IV

PERANCANGAN

Pada bab ini akan membahas mengenai perancangan penelitian tugas akhir, yang berkaitan dengan bagaimana model peramalan *Artificial Neural Network* akan dibangun untuk meramalkan tingkat inflasi di Indonesia. Bab ini juga menjelaskan bagaimana data dikelola untuk dapat menentukan variable dan scenario yang akan digunakan untuk mencari model terbaik.

4.1 Pengumpulan Data

Pada tahap ini dilakukan pengumpulan data yang akan digunakan dalam pelaksanaan penelitian tugas akhir. Dalam penentuan data, seperti apa yang telah dijelaskan pada bab pendahuluan, penelitian ini menggunakan variable inflasi pada negara mitra dagang, kegiatan impor bahan mentah dan nilai rupiah terhadap kurs. Namun variable kegiatan impor bahan mentah tidak dapat digunakan karena keterbatasan ketersediaan data. Variable inflasi mitra dagang didapatkan dari web www.gdpinflation.com [7]. Negara yang dipilih sebagai variable uji coba merupakan beberapa negara dengan nilai impor terbesar ke Indonesia untuk bahan baku dan pendukung industri. Sehingga negara Malaysia, Thailand, Filipina, Cina, Amerika dan Jepang dipilih sebagai variable negara mitra dagang [5]. Kurs nilai rupiah terhadap dollar didapatkan dari website Investing.com.

4.2 Pengolahan Data

Setelah semua data yang dibutuhkan telah didapatkan, langkah selanjutnya adalah mengolah data tersebut agar dapat digunakan untuk melakukan peramalan. Beberapa hal yang dilakukan adalah

penyusunan pola data untuk menyesuaikan pola yang dapat dibaca oleh MATLAB. Selain pola, format data juga diubah untuk menyesuaikan format yang dapat dibaca MATLAB, uji korelasi juga dilakukan pada data variable negara mitra dagang untuk melihat negara mana yang memiliki nilai korelasi yang baik dengan inflasi di Indonesia. Uji korelasi dilakukan di Excel. Berdasarkan hasil uji korelasi, hanya negara Malaysia dan Filipina yang memiliki nilai korelasi yang cukup baik antara inflasi pada negara tersebut dengan inflasi di Indonesia.

4.3 Pemodelan Artificial Neural Network

Pada tahap ini dilakukan perancangan model Artificial Neural Network untuk dapat melakukan peramalan tingkat inflasi di Indonesia menggunakan data-data yang telah dikumpulkan dan diolah sebelumnya. Tujuan pemodelan ANN adalah untuk mendapatkan model terbaik yang dapat melakukan peramalan dengan tingkat akurasi tertinggi, sehingga memberikan hasil peramalan paling optimal.

4.3.1 Pembagian Data

Lagkah pertama dalam membangun model Artificial Neural Network adalah dengan membagi data yang akan digunakan untuk peramalan. Data yang akan digunakan untuk peramalan dibagi menjadi dua, yaitu data pelatihan (*training*) dan data pengujian (*testing*). Data *training* digunakan untuk mencari bobot dalam melakukan peramalan yang selanjutnya diujikan kepada data *testing*. Dari data bulanan dari bulan Januari 1995 sampai dengan Maret 2017 yang berjumlah 268 data. 75% data digunakan sebagai data *training* dan 25% lainnya digunakan sebagai data *testing*, yang menjadikan 201 data digunakan sebagai data *training* dan 67 data

dijadikan sebagai data *testing*. Pembagian data ini dilakukan untuk seluruh variable yang akan digunakan sebagai input peramalan.

4.3.2 Penentuan Input

Setelah semua data yang dibutuhkan telah sesuai dan dapat digunakan, pada sub bab ini dilakukan penentuan scenario uji coba dalam menggunakan variable – variable yang telah didapatkan. Variable yang telah didapatkan akan mengisi node-node pada bagian *input layer*, yang merupakan layer paling depan atau bagian terdepan dalam struktur ANN. **Table 4.1** di bawah akan menyebutkan variable apa saja yang digunakan pada penelitian ini.

Tabel 4.1 Variable Penelitian

No	Variable
1	Nilai Inflasi di Indonesia
2	Nilai Inflasi di Malaysia
3	Nilai Inflasi di Thailand
4	Nilai Inflasi di Filipina
5	Nilai Inflasi di China
6	Nilai Inflasi di Amerika
7	Nilai Inflasi di Jepang
8	Nilai tukar rupiah

Dalam melakukan uji coba untuk mencari model peramalan terbaik, kedelapan variable diatas akan dikombinasikan penggunaannya. Penggunaan kombinasi variable dilakukan dengan tujuan membandingkan penggunaan variable terhadap akurasi hasil peramalan. Untuk lebih jelasnya dijelaskan menggunakan table di bawah.

Tabel 4.2 Penggunaan Variable

INPUT 1	
Jumlah Node	1
Variable	Nilai Inflasi di Indonesia
Alasan	Penggunaan satu variable ini bertujuan untuk menjadi landasan atau dasar peramalan. Sehingga dapat menjadi pembanding apakah variable tambahan lainnya dapat memberikan akurasi peramalan yang lebih baik.
INPUT 2	
Jumlah Node	2
Variable	Nilai Inflasi di Indonesia dan Nilai tukar rupiah
Alasan	Penambahan variable nilai tukar rupiah dilakukan sebab

	variable ini memiliki hubungan langsung dan nilai korelasi yang baik
INPUT 3	
Jumlah Node	8
Variable	Tingkat inflasi di Indonesia, Malaysia, Thailand, Filipina, Amerika, Jepang, China dan kurs rupiah
Alasan	Pada input 3 ini semua variable dimasukkan. Variable didapatkan bedasarkan referensi yang menyatakan negara tersebut merupakan negara dengan tingkat nilai export tertinggi dibandingkan dengan negara lain yang memiliki hubungan kerjasama ekonomi dengan Indonesia.

INPUT 4	
Jumlah Node	4
Variable	Tingkat inflasi di Indonesia, Malaysia, Filipina, dan kurs rupiah
Alasan	Pada input 4 ini beberapa negara mitra dagang dihilangkan karena setelah dilakukan uji korelasi seperti yang telah dijelaskan sebelumnya pada sub-bab Pengolahan Data. Sehingga didapatkan negara Malaysia dan Filipina lah yang memiliki nilai korelasi baik dengan nilai inflasi di Indonesia.

4.3.3 Penentuan Parameter

Disamping mementukan input yang terletak pada *input layer*, dalam ANN diperlukan juga menentukan penggunaan parameter yang terletak pada *hidden layer*. Dalam penggunaan paramteter pada penelitian ini menggunakan metode try-and-error dimana masing-masing parameter diuji dan dipasangkan satu-persatu untuk mendapatkan hasil peramalan dengan akurasi tertinggi yang dapat dilihat dari nilai error terkecil. Parameter yang akan diubah-

ubah pada penelitian ini adalah jumlah node pada *hidden layer* , fungsi pelatihan, fungsi aktivasi, fungsi performa dan fungsi pembelajaran. Berikut penjelasan lebih lanjut mengenai parameter yang akan digunakan :

a. Jumlah node pada *hidden layer*

Berfungsi untuk memberikan bobot dan nilai pada input yang didapatkan dari node pada *input layer*. Jumlah node yang tepat kurang lebih berada diantara ukuran atau jumlah node pada *hidden layer* dan *output layer* [22]. Jumlah node pada *hidden layer* membeirkan pengaruh yang besar dalam menemukan model dengan tingkat akurasi peramalan terbaik. Pada penelitian ini jumlah layer yang digunakan diuji satu-persatu dari mulai 2 hingga 21 node pada layer tersebut.

b. Fungsi pelatihan

Fungsi pelatihan berfungsi dalam melatih network dalam memahami pattern untuk dapat melakukan peramalan dengan baik. Dari total 12 fungsi pelatihan pada MATLAB, hanya dua fungsi pelatihan yang diguanakan pada penelitian ini, yaitu Lavenberg-Marquardt (LM), BFGS Quasi-Newton (BFG) yang digunakan berdasarkan hasil uji coba yang dilakukan MATLAB terhadap beberapa fungsi pembelajaran lainnya [20].

c. Fungsi aktivasi

Fungsi aktivasi berguna untuk menghitung nilai dari hasil pengelolahan bobot yang sebelumnya dilakukan di node pada *hidden layer*. Fungsi aktivasi diberikan pada setiap layer, baik pada *hidden layer* untuk ditransferkan ke *output layer*, maupun dari *output layer* untuk dihasilkan menjadi output. Terdapat tiga fungsi aktivasi yang digunakan pada

penelitian ini seperti yang telah dijelaskan pada bab dasar teori, yaitu Logsigmoid (logsig), Tansigmoid (tansig) dan Purelin dimana ketiga fungsi aktivasi ini digunakan pada *hidden layer*. Sedangkan pada *output layer* hanya akan menggunakan fungsi Purelin.

d. Fungsi performa

Untuk mencari model terbaik, dapat dicari dengan meliat performa model yang didapatkan dari perhitungan error atau selisih antara hasil peramalan dengan target output yang dikehendaki. Pada penelitian ini digunakan Mean Squared Error (MSE) sebagai fungsi dalam menghitung error tersebut.

e. Fungsi pembelajaran

Fungsi pembelajaran memberikan nilai rate pembelajaran atau kecepatan network dalam mencari dan memberikan gradient yang paling optimal terhadap bobot dan bias pada model. Pada penelitian ini digunakan dua fungsi pembelajaran yaitu *learningdm* dan *learningd*.

Tabel 4.3 Parameter Penelitian

Parameter	Penggunaan
Jumlah node pada hidden layer	2 sampai 21
Jumlah hidden layer	1
Fungsi pelatihan	<ul style="list-style-type: none"> • Lavenberg-Marquardt (LM) • BFGS Quasi-Newton (BFG)
Fungsi aktivasi	<ul style="list-style-type: none"> • Logsigmoid

Parameter	Penggunaan
	<ul style="list-style-type: none"> • Transigmoid • Purelin
Fungsi performa	MSE
Fungsi pembelajaran	<ul style="list-style-type: none"> • <i>Learningd</i> • <i>learningdm</i>
Epoch	100

Disamping kelima parameter diatas, terdapat parameter lain dengan nilai yang tetap seperti jumlah layer pada *hidden layer*, jumlah node pada *output layer*, epoch dan fungsi pelatihan pada *output layer*. Table 4.3 merangkum parameter apa saja yang digunakan pada penelitian ini.

4.3.4 Penentuan Output

Output yang dihasilkan dari model ini adalah sebuah variable berupa nilai peramalan tingkat inflasi di Indonesia sejumlah n periode. Penentuan jumlah periode hasil peramalan menentukan jumlah node pada bagian output. Periode peramalan yang digunakan pada penelitian ini adalah 1, 3, 6 dan 12 bulan kedepan. Disamping periode peramalan, periode data yang digunakan untuk melakukan peramalan juga ditentukan dengan jumlah 1 sampai 12 bulan kebelakang. Sehingga terdapatlah scenario output.

Skenario berdasarkan periode peramalan sendiri dibuat berdasarkan n periode data historis yang dibaca sebagai input, dan

n periode output sebagai hasil peramalan, sehingga terbentuk menjadi 48 skenario sebagai berikut :

Tabel 4.4 Skenario periode peramalan

Skenario	Periode Output	Periode Input
1 - 12	1 bulan	1 - 12 bulan
13 - 24	3 bulan	1 - 12 bulan
25 – 36	6 bulan	1 - 12 bulan
37 – 48	12 bulan	1 - 12 bulan

4.3.5 Pengembangan Skenario Uji Coba Model

Skenario dibuat berdasarkan variasi penggunaan variable dan periode peramalan. Untuk skenario berdasarkan penggunaan variable, seluruhnya dilakukan untuk peramalan periode satu bulan kedepan, hal tersebut dilakukan sebab peramalan dengan periode satu bulan cenderung memberikan akurasi tertinggi jika dibandingkan dengan peramalan dengan jumlah periode diatas satu bulan. Berdasarkan penggunaan variable dibuat empat skenario uji coba yaitu :

- Satu variable; Tingkat inflasi di Indonesia
- Dua variable; Tingkat inflasi Indonesia dan Kurs rupiah
- Empat variable; Tingkat inflasi Indonesia, Malaysia, Filipina dan Kurs rupiah
- Delapan variable; Tingkat inflasi Indonesia, Malaysia, Thailand, Filipina, Amerika, Jepang, China dan kurs rupiah

Setelah uji coba skenario berdasarkan penggunaan variable dilakukan, didapatkan bahwa model dengan empat variable memberikan hasil peramalan yang paling baik -hasil uji coba skenario dibahas pada bab VI- sehingga skenario uji coba berdasarkan periode peramalan, dikembangkan dari model dengan empat variable tersebut. Pengembangan selanjutnya adalah dengan menentukan jumlah periode output peramalan. Seperti yang telah dijelaskan pada **Tabel 4.4** terdapat total 48 skenario output.

Sehingga jika digabungkan dari penggunaan variable pada *input layer*, seluruh parameter pada *hidden layer*, dan periode peramalan pada *output layer*. Akan terbentuk total 53 skenario yang akan dijalankan untuk mencari model peramalan terbaik. Table di bawah menjelaskan beberapa skenario awal yang dijalankan untuk penelitian ini. Sebab parameter yang diujikan pada hidden layer diberlakukan untuk semua skenario, maka bagian hidden layer hanya akan ditunjukkan pada Tabel 4.5.

Tabel 4.5 Skenario Penelitian I

Skenario 1		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia
Hidden Layer	Jumlah node pada hidden layer	2 sampai 21
	Jumlah hidden layer	1

Skenario 1		
Layer	Parameter	Deskripsi
	Fungsi pelatihan	<ul style="list-style-type: none"> • Lavenberg-Marquardt (LM) • BFGS Quasi-Newton (BFG)
	Fungsi aktivasi	<ul style="list-style-type: none"> • Logsigmoid • Transigmoid • Purelin
	Fungsi performa	MSE
	Fungsi pembelajaran	<ul style="list-style-type: none"> • <i>Learningd</i> • <i>learningdm</i>
	Epoch	100
Output	Periode input	1 bulan
	Periode output	1 bulan

Tabel 4.6 Skenario Penelitian 2

Skenario 2		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Kurs rupiah
Output	Periode input	1 bulan
	Periode output	1 bulan

Tabel 4.7 Skenario Penelitian 3

Skenario 3		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Thailand • Tingkat inflasi di Filipina

Skenario 3		
Layer	Parameter	Deskripsi
		<ul style="list-style-type: none"> • Tingkat inflasi di Jepang • Tingkat inflasi di China • Tingkat inflasi di Amerika • Kurs rupiah
Output	Periode input	1 bulan
	Periode output	1 bulan

Tabel 4.8 Skenario Penelitian 4

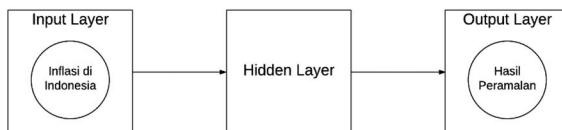
Skenario 4		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 4		
Layer	Parameter	Deskripsi
Output	Periode input	1 bulan
	Periode output	1 bulan

Skenario selebihnya, perubahan hanya dilakukan pada periode input dan output. Dimana periode output akan ditetapkan dengan nilai 1, 3, 6, dan 12 sedangkan periode input diujikan dari 1 sampai 12 periode. Skenario lebih lengkapnya akan ditampilkan pada lampiran A bagian pemaparan skenario peramalan.

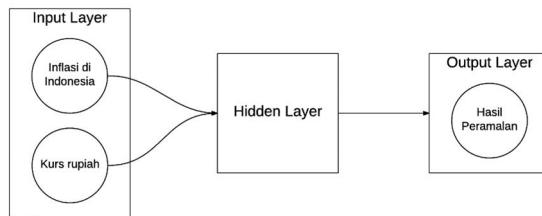
4.3.6 Struktur Artificial Neural Network

Seperti yang telah diketahui bahwa *Artificial Neural Network* memiliki struktur atau bentuk seperti struktur jaringan saraf yang dimiliki oleh manusia. Seperti halnya saraf manusia yang memiliki receptor, connector dan motor, ANN memiliki *input layer*, *hidden layer* dan *output layer* dengan fungsi yang menyerupai. Berdasarkan scenario yang telah terbentuk pada bab sebelumnya, maka struktur dari *input layer*, *hidden layer* dan *output layer* akan digambarkan pada sub-bab ini.



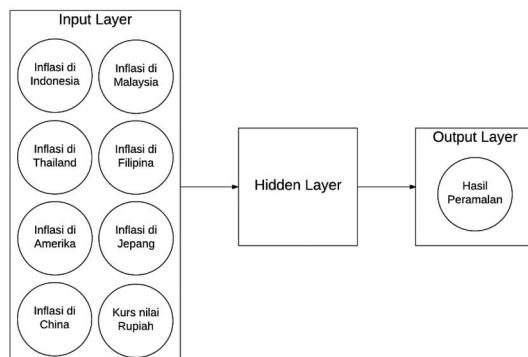
Gambar 4.1 Struktur ANN dari Skenario 1

Pada skenario 1, *input layer* dan *output layer* hanya memiliki satu variable sehingga terbentuk struktur ANN seperti di atas. Sedangkan pada Skenario 2, *input layer* memiliki dua node yaitu Inflasi di Indonesia dan Kurs rupiah dengan *output* dan *hidden layer* yang sama.

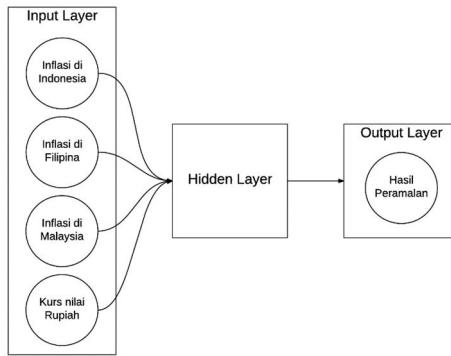


Gambar 4.2 Struktur ANN dari Skenario 2

Begitu juga pada Skenario 3 dimana hanya terjadi penambahan pada jumlah variable pada *input layer* menjadi 8 input dengan memasukkan negara mitra dagang sebagai variable input.

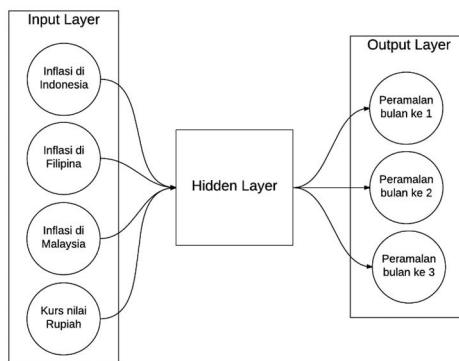


Gambar 4.3 Struktur ANN dari Skenario 3



Gambar 4.4 Struktur ANN dari Skenario 4

Pada Skenario 4 dan 5 variable yang digunakan sebagai input sama, yaitu inflasi di Indonesia, negara mitra dagang yang dipilih berdasarkan nilai korelasi dengan inflasi Indonesia, dan nilai kurs rupiah. Namun pada skenario 4 sama seperti sebelumnya, output yang dihasilkan hanyalah satu periode atau satu bulan kedepan, sedangkan skenario 5 menghasilkan peramalan untuk tiga periode atau tiga bulan kedepan.



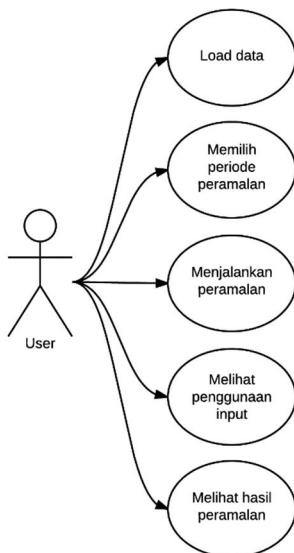
Gambar 4.5 Struktur ANN dari Skenario 5

Struktur skenario selebihnya menyerupai hubungan skenario 4 dan 5 dimana hanya terjadi perubahan pada jumlah output sesuai dengan jumlah periode peramalan.

4.3.7 Pengembangan Aplikasi

Setelah mendapatkan model terbaik dalam peramalan untuk masing-masing periode 1, 3, 6 dan 12 bulan, maka langkah selanjutnya adalah membangun sebuah aplikasi sederhana yang berfungsi untuk mempermudah user yang hendak melakukan peramalan menggunakan model-model terbaik yang telah didapatkan. Aplikasi akan dibangun menggunakan MATLAB. Use

case diagram pada **gambar 4.6** akan menggambarkan apa saja kegiatan yang dapat dilakukan user.



Gambar 4.0.6 Use Case Diagram

- A. Hal pertama yang perlu dilakukan user adalah me-load data historis yang akan digunakan untuk peramalan
- B. Selanjutnya user dapat memilih jumlah periode peramalan yang dikehendaki, apakah 1, 3, 6, atau 12 bulan kedepan.
- C. Setelah memilih periode dan melakukan peramalan, user dapat melihat data apa saja yang digunakan untuk menjalankan peramalan.

- D. Setelah peramalan dilakukan, user dapat melihat hasil peramalan berupa nilai inflasi pada periode yang ditentukan dan grafik peramalan yang mengikuti sertakan data historisnya sehingga peningkatan dan penurunan tingkat inflasi dapat diamati.

Masing-masing kegiatan yang dilakukan user tersebut merupakan sebuah interaksi dengan system. Selanjutnya masing-masing use case akan dijelaskan melalui *use case scenario* atau *use case description*.

Tabel 4.9 Use Case Load Data

Use Case Scenario Load Data	
Use Case	Load data
Actor	Pengguna aplikasi
Pre Condition	Data inflasi belum dimasukkan
Post Condition	Data inflasi telah dimasukkan
Description	User menentukan data yang akan digunakan untuk melakukan peramalan. System memuat data yang dipilih user.
Main Flow	Actor System

Use Case Scenario Load Data		
	1. Menekan tombol “Load data”	2. Menampilkan dialog windows explorer
	3. Memilih data	4. Memuat data
		5. Menampilkan pesan data telah dimuat
Alternate Flow		

Tabel 4.10 Use Case Periode Peramalan

Use Case Scenario Memilih Periode Peramalan	
Use Case	Memilih periode peramalan
Actor	Pengguna aplikasi
Pre Condition	Data telah dimuat oleh aplikasi
Post Condition	Periode peramalan telah ditentukan

Use Case Scenario Memilih Periode Peramalan		
Description	User menentukan periode atau output jumlah bulan peramalan yang dikehendaki, baik 1, 3, 6, ataupun 12 bulan	
Main Flow	Actor	System
		1. Memuat model untuk masing-masing periode peramalan
	2. Memilih periode yang diinginkan	
Alternate Flow		

Tabel 4.11 Use Case Menjalankan Peramalan

Use Case Menjalankan Peramalan	
Use Case	Menjalankan peramalan
Actor	Pengguna aplikasi
Pre Condition	Data inflasi telah dimasukkan dan periode peramalan telah dipilih.

Use Case Menjalankan Peramalan		
Post Condition	Peramalan telah dilakukan dan dapat ditampilkan	
Description	User menjalankan proses peramalan yang dilakukan oleh system.	
Main Flow	Actor	System
	1. Menekan tombol “Forecast”	2. Membaca jumlah periode yang dikehendaki
		3. Mengambil data sebagai input sesuai model
		4. Memilih model yang sesuai
		5. Melakukan peramalan
Alternate Flow		2.1. User belum menentukan periode peramalan
		3.1. User belum menentukan data yang perlu dimuat

Tabel 4.12 Use Case Melihat Input

Use Case Scenario Melihat Penggunaan Input		
Use Case	Melihat penggunaan input	
Actor	Pengguna aplikasi	
Pre Condition	Peramalan telah dilakukan	
Post Condition	User mengetahui data yang digunakan untuk peramalan	
Description	User dapat memantau data apa yang diambil dan diramalkan oleh system untuk memastikan system telah melakukan peramalan sesuai dengan keinginan.	
Main Flow	Actor	System
		1. Menampilkan input yang digunakan
	2. Melihat input yang digunakan	
	3. Memastikan data yang digunakan sesuai dengan keinginan	

Tabel 4.13 Use Case Hasil Peramalan

Use Case Scenario Melihat Hasil Peramalan		
Use Case	Melihat hasil peramalan	
Actor	Pengguna aplikasi	
Pre Condition	Peramalan telah dilakukan	
Post Condition	User mengetahui hasil dari peramalan	
Description	User dapat melihat hasil peramalan yang telah dilakukan baik dalam bentuk nilai maupun grafik.	
Main Flow	Actor	System
		1. Menampilkan nilai hasil peramalan
		2. Menampilkan grafik hasil peramalan
	3. Melihat nilai hasil peramalan	
	4. Melihat grafik hasil peramalan	

4.3.8 Pengembangan Interface Aplikasi

Aplikasi yang akan dibangun, akan diberikan interface atau antarmuka sehingga user akan lebih mudah dalam menggunakannya. Seperti yang telah disebutkan pada use case diagram pada gambar 4.6 mengenai apa saja yang dapat dilakukan oleh user, maka interface akan dirancang untuk dapat memenuhi use case tersebut dimana akan terdapat:

- a. Header yang menjadi title dari aplikasi
- b. Tombol “Load Data” untuk memuat data yang dapat dicari dari browser
- c. Label status data, berisikan informasi apakah data sudah dimuat atau belum
- d. Menu periode peramalan, yang akan berisi pilihan untuk melakukan peramalan baik 1, 3, 6, maupun 12 bulan
- e. Tombol “Forecast” untuk menjalankan proses peramalan
- f. Table input, berisikan data-data yang digunakan untuk melakukan peramalan
- g. Table hasil peramalan, yang berisikan nilai-nilai hasil peramalan sesuai dengan periode peramalan
- h. Grafik hasil peramalan, memberikan gambaran grafik pada user untuk melihat historis naik turunnya nilai inflasi dan melihat forecast dalam bentuk grafik untuk memberikan kemampuan analisa bagi user.

(halaman ini sengaja dikosongkan)

BAB V

IMPLEMENTASI

Pada bab ini akan membahas mengenai implementasi model peramalan yang sebelumnya telah dirancang pada bab IV mengenai perancangan. Bab ini juga menjelaskan proses-proses yang dilakukan dalam mendapatkan model peramalan terbaik sesuai dengan perancangan pencarian model terbaik.

5.1 Pengolahan data

Langkah pertama yang dilakukan untuk menentukan mencari model ANN adalah dengan membuat file data yang sesuai dengan variable dan periode peramalan yang digunakan. Pada **table 5.1** dapat dilihat variable apa saja yang digunakan pada penelitian.

Tabel 5.1 Variable

Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
0,0953	0,0350	0,0260	0,0490	0,0580	0,2410	0,0280	0,0050	2217,0
0,0903	0,0310	0,0240	0,0480	0,0500	0,2240	0,0286	0,0020	2216,5
0,0891	0,0330	0,0260	0,0470	0,0560	0,2130	0,0285	-0,0030	2238,0
0,1048	0,0330	0,0230	0,0530	0,0560	0,2070	0,0305	-0,0020	2233,0
0,1046	0,0380	0,0220	0,0540	0,0630	0,2030	0,0319	-0,0010	2226,5
0,1050	0,0390	0,0180	0,0540	0,0660	0,1820	0,0304	0,0020	2227,0
0,0976	0,0380	0,0150	0,0560	0,0640	0,1670	0,0276	0,0010	2235,0
0,0914	0,0380	0,0140	0,0600	0,0680	0,1450	0,0262	-0,0020	2266,5
.....

Terdapat total 264 record data yang digunakan pada penelitian ini untung masing-masing variable. Dari kedelapan variable ini akan dibuat 4 skenario seperti yang telah disebutkan pada bab-bab sebelumnya.

Agar data dapat digunakan, data diolah sesuai dengan periode peramalan. Jika ingin meramalakan untuk satu periode kedepan, maka dibuat satu kolom baru yang berisikan target peramalan, dengan menggeser data satu periode kedepan. Karena data yang digunakan diurutkan secara *ascending* atau data terbaru terletak di paling bawah table, maka data untuk peramalan satu periode akan terlihat seperti pada **table 5.2**.

Tabel 5.2 Data periode 1

Indo	Malay	Phil	Kursa	Output
0,0953	0,0350	0,0580	2217,0	0,0903
0,0903	0,0310	0,0500	2216,5	0,0891
0,0891	0,0330	0,0560	2238,0	0,1048
.....
0,0321	0,0105	0,0191	13098,5	0,0279
0,0279	0,0149	0,0184	13267,5	0,0307
0,0307	0,0149	0,0226	13051,0	0,0331
0,0331	0,0140	0,0233	13048,0	0,0358
0,0358	0,0183	0,0246	13552,5	0,0302
0,0302	0,0183	0,0259	13472,5	0

Data diatas merupakan contoh data dengan 4 variable sebagai input peramalan yang telah dapat digunakan untuk dicari model

terbaiknya menggunakan MATLAB. **Data denga highlight hitam merupakan data yang tidak digunakan.** Pengolahan data dilakukan untuk masing-masing skenario perncarian model terbaik berdasarkan penggunaan variable seperti yang telah dicontohkan pada table 5.2.

Sedangkan untuk peramalan dengan periode lebih dari 1 bulan maka target atau output dibuat sejumlah periode peramalan sehingga akan terbentuk data seperti pada **tabel 5.3**

Tabel 5.1 Data Periode 3

Indo	Malay	Phil	Kursa	Target 1	Target 2	Target 3
0,0953	0,035	0,058	2217	0,0903	0,0891	0,1048
0,0903	0,031	0,05	2216,5	0,0891	0,1048	0,1046
0,0891	0,033	0,056	2238	0,1048	0,1046	0,1050
0,1048	0,033	0,056	2233	0,1046	0,1050	0,0976
0,1046	0,038	0,063	2226,5	0,1050	0,976	0,914
....
0,0345	0,0159	0,0191	13212,5	0,0321	0,0279	0,0307
0,0321	0,0105	0,0191	13098,5	0,0279	0,0307	0,0331
0,0279	0,0149	0,0184	13267,5	0,0307	0,0331	0,0358
0,0307	0,0149	0,0226	13051	0,0331	0,0358	0,0302
0,0331	0,014	0,0233	13048	0,0358	0,0302	0
0,0358	0,0183	0,0246	13552,5	0,0302	0	0
0,0302	0,0183	0,0259	13472,5	0	0	0

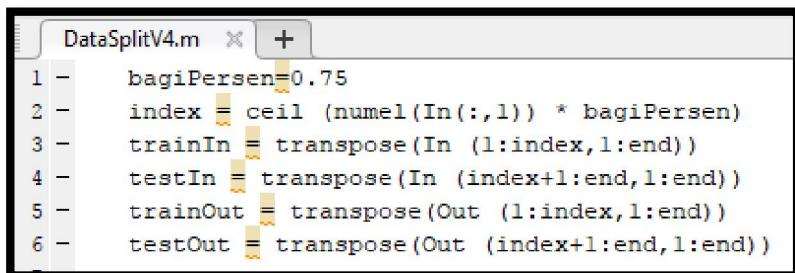
Sama seperti peramalan periode tiga bulan, pada periode peramalan 6 dan 12 bulan, dibuat target sejumlah periode peramalan. Data lebih lengkap akan disampaikan pada lampiran B.

5.2 Pemodelan ANN terbaik

Setelah data yang dibutuhkan telah diolah dan dapat digunakan. Langkah selanjutnya adalah mulai mencari model peramalan terbaik. Pemodelan dilakukan menggunakan matlab, dengan menjalankan 2 jenis program. Pengertian dari program itu sendiri adalah serangkaian instruksi untuk menjalankan sebuah fungsi [23], dimana fungsi program ini adalah untuk melakukan pembagian data dan program lainnya berfungsi untuk mencarian model terbaik. Data yang sudah siap dibagi menggunakan program pembagian data. Jika sudah terdapat data testing dan training selanjutnya dilakukan pencarian model terbaik menggunakan program pencarian model terbaik.

5.2.1 Pembagian Data

Dalam melakukan pembagian data, dibuat program sederhana untuk mempermudah prosesnya. Berikut program yang digunakan untuk membagi data.



```

DataSplitV4.m
bagiPersen=0.75
index = ceil (numel(In(:,1)) * bagiPersen)
trainIn = transpose(In (1:index,1:end))
testIn = transpose(In (index+1:end,1:end))
trainOut = transpose(Out (1:index,1:end))
testOut = transpose(Out (index+1:end,1:end))

```

Skrip 5.1 Membagi Data

Untuk melakukan pembagian data, pertama diperlukan sebuah variable pada MATLAB untuk membagi data input dan data target. Data dibagi dengan rasio 75:25 untuk data *training : testing*.

```

1 - bagiPersen=0.75
2 - index = ceil (numel(In(:,1)) * bagiPersen)

```

Skrip 5.2 Persentase Bagi Data

Untuk melakukannya, variable “In” dibuat untuk menyimpan data input peramalan, dan variable “Out” untuk menyimpan target pelatihan. Sebab MATLAB membaca data dengan arah berdasarkan baris, sedangkan data yang disiapkan diurutkan berdasarkan kolom, maka dilakukan transpose saat membaca data.

```

3 - trainIn = transpose(In (1:index,1:end))
4 - testIn = transpose(In (index+1:end,1:end))
5 - trainOut = transpose(Out (1:index,1:end))
6 - testOut = transpose(Out (index+1:end,1:end))

```

Skrip 5.3 Mengisi Data Train dan Test

Program ini menghasilkan variable “trainIn”, “trainOut”, “testIn” dan “testOut”. Variable trainIn dan trainOut merupakan data *training* dengan komposisi 75% dari total data. Sedangkan variable testIn dan testOut berisikan data *testing*.

5.2.2 Pencarian Model Terbaik

Untuk mencari model terbaik, masing-masing scenario dijalankan menggunakan program yang secara berulang-ulang mencoba mengkombinasikan setiap parameter yang telah ditentukan. Sebuah model ANN dibentuk dengan script pada gambar 5.4.

```
model = newff(trainIn, trainOut , node, {cell2mat(activation(a)), 'purelin'});
model.trainFcn=cell2mat(train(b));
model.trainParam.EPOCHS=100;
model.performFcn = 'mse';
model.layerWeights{1,1}.learnFcn = cell2mat(learn(c));
```

Skrip 5.4 Membuat Model

Model tersebut diisi dengan parameter seperti yang telah ditentukan pada bab penentuan parameter, gambar 5.5 mendeklarasikan parameter fungsi aktivasi, pelatihan dan pembelajaran apa saja yang digunakan untuk model.

```
activation = {'logsig' 'tansig' 'purelin'}
train = {'trainlm' 'trainbfg'}
learn = {'learngd' 'learngdm' }
```

Skrip 5.5 Penggunaan Parameter

Parameter tersebut diisikan ke dalam model dengan menggunakan nested looping sebagai berikut.

```
A = numel(activation)
B = numel(train)
C = numel(learn)
```

Skrip 5.6 Inisialisasi Variable Loop

```

for node=2:21
    for a=1:A
        for b=1:B
            for c=1:C

```

Skrip 5.7 Nested Looping

Dalam menguji model peramalan, pertama model dilatih menggunakan data *training* dan langsung disimulasikan menggunakan data “*testIn*”. Setelah output didapatkan dari simulasi, akurasi peramalan dihitung menggunakan MSE untuk mencari model yang paling stabil, dengan mencari kuadrat selisih output simulasi dengan variable “*testOut*” sebagai target peramalan. Saat melakukan simulasi, setiap model yang dijalankan disimpan berikut dengan hasil output simulasinya. Pada gambar 5.8 berikut script yang digunakan untuk melakukan *training*, simulasi, menghitung MSE dan penyimpanan hasil simulasinya.

```

[modell,tr]=train(model,trainIn,trainOut);
siml =sim(modell,testIn);
xlsSiml=['simA', num2str(z),'.xls'];
matSiml=[ num2str(z),'simA','.mat'];
save (matSiml, 'modell');

xlswrite(xlsSiml,siml);
hitungMSE1=(testOut-siml).^2 |
MSE1 = mean(mean(hitungMSE1,2))
tempoMse (z,1,:)= transpose(MSE1)

```

Skrip 5.8 Simulasi Model

MSE yang telah dihitung dicari nilai terkecilnya untuk mendapatkan model terbaik. Perhitungan dari masing-masing MSE juga disimpan dalam satu file excel. Berikut script yang digunakan untuk mencari MSE terbaik.

```
mse= min(min(MSE1,MSE2),MSE3);
if bestMse > mse
    bestMse = min(min(MSE1,MSE2),MSE3);
    bestTransf = cell2mat(activation(a));
    bestLearnf = cell2mat(train(b));
    bestNode = node;
    bestEpoch = d;
    bestTrainf = cell2mat(learn(c));
end

saveTempoMse = squeeze(tempoMse (z,:,:))
saveSummary{z, 1} = node;
saveSummary{z, 2} = cell2mat(activation(a));
saveSummary{z, 3} = cell2mat(learn(c));
saveSummary{z, 4} = cell2mat(train(b));
saveSummary{z, 5} = epoch(d);
saveSummary{z, 6} = saveTempoMse(1, 1);
saveSummary{z, 7} = saveTempoMse(1, 2);
saveSummary{z, 8} = saveTempoMse(1, 3);

xlswrite('summaryMSE' ,saveSummary);
```

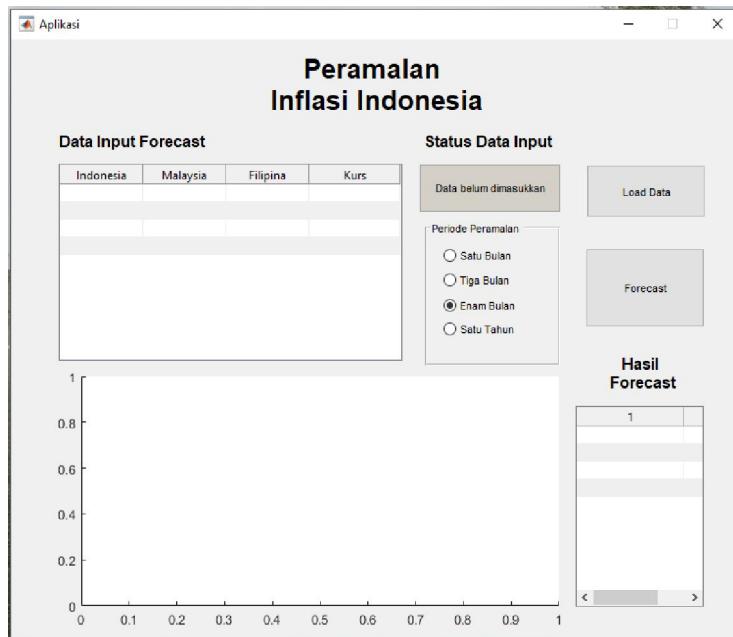
Skrip 5.9 Mencari MSE Terbaik

Selanjutnya hasil predksi model terbaik dihitung MAPE nya secara manual terhadap nilai akutal untuk mendapatkan perhitungan nilai error yang lebih baik.

5.3 Pengembangan Aplikasi

Model terbaik yang telah didapatkan selanjutnya dimuat oleh aplikasi. Aplikasi ini akan memuat 4 model terbaik untuk melakukan peramalan sesuai dengan periode peramalan secara otomatis saat aplikasi dijalankan.

Selanjutnya akan dibahas mengenai interface dan fungsi yang dapat dilakukan oleh user. Gambar 5.10 di bawah merupakan tampilan dari aplikasi.

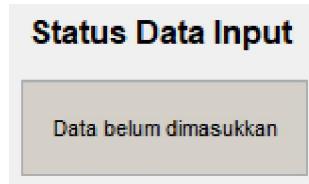


Gambar 5.1 Interface Aplikasi

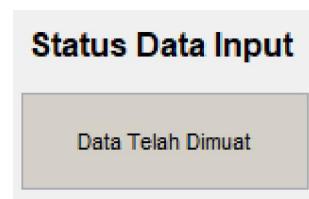
Terdapat beberapa fungsi yang dapat dilakukan pada aplikasi peramalan yang dibangun ini. Berikut penjelasan fungsi-fungsi dan tombol pada aplikasi:

1. Label “Status Data Input”

Label ini berfungsi untuk memberikan informasi pada user apakah data peramalan telah dimuat atau belum. Gambar 5.11 merupakan tampilan saat data belum dimuat, sedangkan gambar 5.12 merupakan tampilan saat data sudah dimuat.



Gambar 5.21 Status input 1



Gambar 5.3 Status Input 2

2. Tombol Load Data

Tombol ini berfungsi untuk memilih file data yang akan digunakan untuk peramalan dengan membuka window windows explorer untuk mencari data yang diperlukan.

3. List Periode Peramalan

List ini berfungsi untuk memilih periode peramalan, terdapat empat pilihan periode peramalan yaitu 1, 3, 6 dan 12 bulan kedepan.

4. Tombol “Forecast”

Tombol ini menjalankan script fungsi peramalan yang terdapat di dalam aplikasi. Saat tombol ditekan, aplikasi akan menjalankan :

- Meninjau apakah data telah dimuat
 - Meninjau apakah periode peramalan telah dipilih
 - Memilih model yang akan digunakan sesuai dengan periode peramalan yang dipilih
 - Melakukan peramalan
 - Menampilkan hasil peramalan
5. Tabel “Data Input Forecast”

Table ini menampilkan data yang digunakan untuk melakukan peramalan. Gambar 5.13 di bawah merupakan contoh penggunaan 6 periode untuk peramalan.

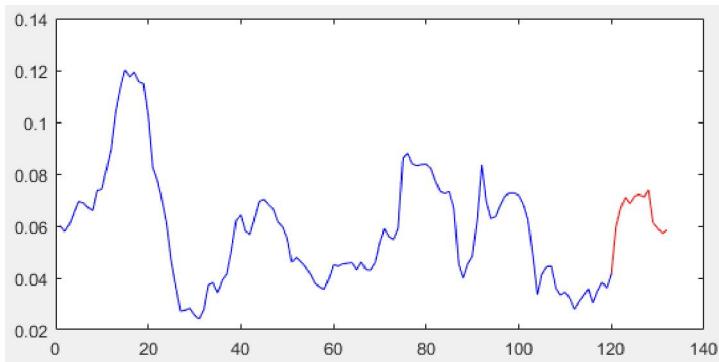
Data Input Forecast

Indonesia	Malaysia	Filipina	Kurs
0.0358	0.0183	0.0246	1.3553e+04
0.0302	0.0183	0.0259	13352
0.0349	0.0323	0.0272	13336
0.0383	0.0454	0.0330	1.3326e+04
0.0361	0.0510	0.0344	13329
0.0417	0.0482	0.0342	13322

Gambar 5.4 Data Input Forecast

6. Grafik Peramalan

Hasil peramalan berupa grafik ditampilkan pada grafik dengan juga menampilkan grafik data historis agar user dapat melakukan analisis.



Gambar 5.5 Grafik Peramalan

7. Nilai Peramalan

Selain menggunakan grafik, hasil peramalan juga ditampilkan dalam bentuk angka pada tabel hasil peramalan berikut.

Hasil Forecast	
1	0.0597 ^
	0.0668
	0.0710
	0.0686
	0.0714
	0.0721
	0.0712
	0.0738
	0.0612
	0.0591 v

Gambar 5.6 Hasil Forecast

BAB VI

HASIL DAN PEMBAHASAN

Bab ini akan membahas mengenai hasil dari seluruh uji coba pencarian model terbaik yang dilakukan pada penelitian ini. Berdasarkan pembahasan hasil uji coba tersebut, akan ditentukan model peramalan terbaik yang akan digunakan untuk melakukan peramalan untuk masing-masing periode peramalan yaitu 1, 3, 6, dan 12 bulan. Pembahasan akan dimulai dengan penggunaan lingkup uji coba yang digunakan untuk mencari model terbaik. Selanjutnya dilakukan pembahasan mengenai hasil uji coba pencarian model terbaik berdasarkan variable yang digunakan pada sub-bab 6.2. Dari variable dengan MAPE terbaik, dilakukan uji coba lanjutan dengan mencari periode input terbaik untuk masing-masing periode peramalan pada sub-bab 6.3.

6.1 Lingkungan Uji Coba

Dalam melakukan uji coba, pencarian model peramalan terbaik dijalankan menggunakan perangkat keras dan perangkat lunak tertentu. Sub-bab ini menjelaskan spesifikasi perangkat, baik perangkat keras maupun perangkat lunak yang digunakan dalam penelitian. Seluruh penelitian dilakukan menggunakan laptop dengan spesifikasi *processor* Intel Core i3 2,4 GHz dengan RAM 6GB. Table 6.1 di bawah menjelaskan perangkat lunak apa saja yang digunakan dalam penelitian.

Tabel 6.1 Lingkup Uji Coba

Perangkat Lunak	Fungsi
Windows 10	Sistem Operasi
Matlab 2016	Membuat model peramalan <i>artificial neural network</i> , melakukan uji coba model, membuat aplikasi.
Microsoft Excel 2016	Mengolah data dan menyimpan hasil uji coba peramalan.
Miscrosoft Word 2016	Mencatat dan membuat laporan hasil penelitian

6.2 Uji Penggunaan Variable

Berdasarkan penggunaan variable yang sebelumnya telah ditentukan pada bab 4, bab ini akan membahas hasil uji coba yang telah dilakukan. Untuk mempermudah penjelasan table 6.2 akan menjelaskan penamaan model berdasarkan variable yang digunakan.

Tabel 6.2 Inisialisasi Model

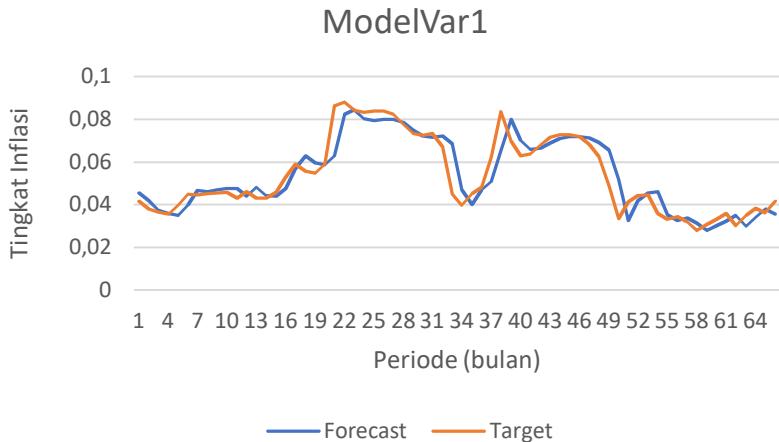
Inisial	Variable yang digunakan
ModelVar1	Tingkat inflasi Indonesia
ModelVar2	Tingkat inflasi Indonesia dan Nilai kurs rupiah
ModelVar3	<ul style="list-style-type: none"> • Tingkat inflasi Indonesia • Tingkat inflasi Malaysia

Inisial	Variable yang digunakan
	<ul style="list-style-type: none"> • Tingkat inflasi Singapura • Tingkat inflasi China • Tingkat inflasi Thailand • Tingkat inflasi Filipina • Tingkat inflasi Amerika • Tingkat inflasi Jepang • Kurs nilai rupiah
ModelVar4	<ul style="list-style-type: none"> • Tingkat inflasi Indonesia • Tingakt inflasi Malaysia • Tingkat inflasi Filipina • Kurs nilai rupiah

6.2.1 ModelVar1

Model dengan satu variable ini digunakan sebagai landasan dalam melakukan peramalan untuk melihat pengaruh variable negara mitra dagang dalam mengingkatkan akurasi permalan tingkat inflasi di Indonesia. Terdapat total 120 model yang diuji yang didapatkan dari hasil kombinasi parameter pada *hidden layer*. Dari 120 model yang diuji, model terbaik dicari dengan melihat output MSE yang disimpan dalam Excel. Selanjutnya dicari MAPE model tersebut dan diapatkan nilai 9.62% dengan parameter :

- | | |
|---------------------|------------|
| Fungsi Aktivasi | : logsig |
| Fungsi Pembelajaran | : trainlm |
| Fungsi Pelatihan | : learngdm |
| Epoch | : 100 |
| Node | : 16 |



Grafik 6.1 ModelVar1

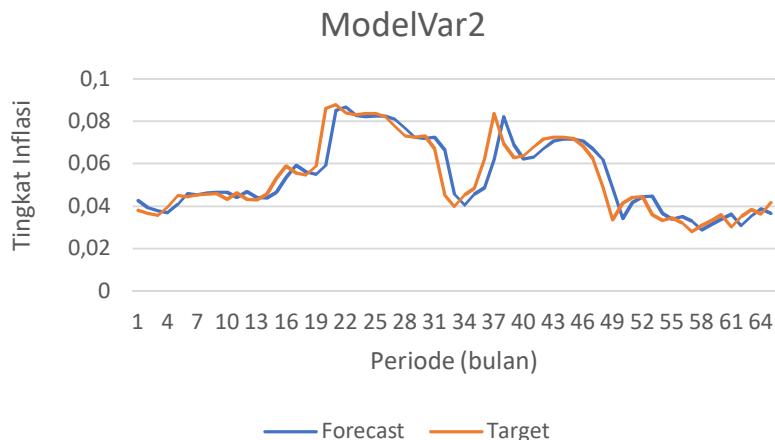
Grafik 6.1 diatas merupakan hasil grafik perbandingan hasil output simulasi dengan target output. MSE akan ditampilkan pada bagian lampiran C-1. Berdasarkan grafik 6.1 di atas, dapat dilihat bahwa hasil *forecast* yang dilakukan model telah memiliki pola yang menyerupai dengan pola target atau data aktual, sehingga model yang didapatkan dapat dikatakan baik.

6.2.2 ModelVar2

Model kedua ini menggunakan dua variable sebagai input peramalan. Pemasangan kedua variable dilakukan karena berdasarkan ilmu ekonomi, nilai inflasi dengan nilai tukar rupiah saling mempengaruhi satu sama lain. Total dari model yang diuji coba untuk 2 variable ini juga berjumlah 120 yang juga merupakan kombinasi parameter pada *hidden layer*. MAPE yang didapatkan untuk model ini adalah 9,10%. ModelVar2 dengan penggunaan dua variable ini ternyata telah memberikan hasil peramalan yang

lebih baik jika dibandingkan dengan ModelVar1. Model terbaik ModelVar2 didapatkan dengan parameter sebagai berikut :

Fungsi Aktivasi	:	purelin
Fungsi Pembelajaran	:	trainlm
Fungsi Pelatihan	:	learngdm
Epoch	:	100
Node	:	14



Grafik 6.2 ModelVar2

Grafik 6.2 di atas merupakan hasil grafik perbandingan hasil output simulasi dengan target atau data aktual. Pada grafik di atas dapat dilihat bahwa pola hasil forecast, dengan garis berwarna biru, memiliki pola yang lebih menyerupai target jika dibandingkan dengan ModelVar1. Hal tersebut menyatakan bahwa model ini lebih baik jika dibandingkan dengan ModelVar1 yang didukung dengan perhitungan MAPE untuk lebih akuratnya.

6.2.3 ModelVar3

Model ini merupakan model dengan variable lengkap negara mitra dagang yang memiliki nilai impor terbersar berdasarkan referensi yang didapatkan. Sama seperti model-model sebelumnya ModelVar3 ini juga memiliki total 120 model yang diujicoba. MAPE yang didapatkan dari model ini adalah 18,4%. Nilai yang jauh lebih buruk jika dibandingkan dengan ModelVar1 yang hanya memiliki error MAPE 9,62%, hampir dua kali lipat error ModelVar1. Parameter yang digunakan untuk model terbaik:

Fungsi Aktivasi	:	logsig
Fungsi Pembelajaran	:	trainlm
Fungsi Pelatihan	:	learngd
Epoch	:	100
Node	:	11

Model ini dapat dikatakan buruk jika dibandingkan dengan model-model sebelumnya. Error yang besar pada model ini disebabkan oleh variable yang tidak memiliki nilai korelasi yang baik satu sama lainnya. Sebab itu pada ModelVar4 dilakukan pemilihan kembali variable dengan melakukan uji korelasi variable, untuk membuang variable dengan nilai korelasi yang kurang baik.

6.2.4 ModelVar4

Dikarenakan ModelVar2 yang tidak memberikan hasil seperti yang diinginkan maka dilakukan uji korelasi untuk variable negara mitra dagang terhadap nilai inflasi di Indonesia. Uji korelasi dilakukan untuk beberapa kurung periode waktu, yaitu dari tahun 1995 – 2016, 2000 – 2016, 2005 – 2016 dan hanya pada tahun 2016. Hal tersebut dilakukan untuk melihat perbedaan korelasi antara kurung waktu tersebut.

Tabel 6.3 Uji Korelasi

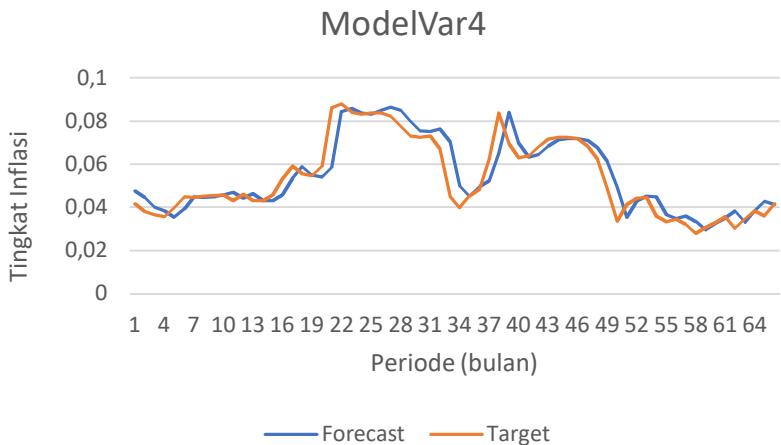
	<i>Tahun</i>	<i>Mal</i>	<i>Spore</i>	<i>Thai</i>	<i>Phil</i>	<i>China</i>	<i>US</i>	<i>Japan</i>
<i>Nilai Korelasi</i>	1995	0,48	-0,26	0,06	0,54	-0,22	-0,04	0,04
	2000	0,39	-0,01	0,08	0,48	-0,11	0,29	0,05
	2005	0,56	0,10	0,11	0,57	0,02	0,47	0,21
	2016	0,83	-0,41	-0,80	-0,72	0,58	-0,33	0,41

Berdasarkan hasil uji korelasi tersebut didapati bahwa Malaysia dan Filipina memiliki nilai korelasi yang baik terhadap nilai inflasi di Indonesia. Sebab itulah ModelVar3 ini hanya mengikutkan negara mitra dagang Malaysia dan Filipina. Disamping itu berdasarkan tabel 6.3 diatas juga menunjukkan bahwa nilai korelasi semakin meningkat ketika data yang digunakan mendekati tahun terkini. Hal tersebut disebabkan oleh terjadinya krisis ekonomi di Indonesia pada tahun 1998 akibat kerusuhan reformasi, sehingga nilai korelasi pada tahun 1995 – 2000 cenderung kecil jika dibandingkan negara-negara mitra dagang. Dan setelah tahun 2005 kondisi ekonomi di Indonesia mulai stabil sehingga nilai korelasi dengan negara-negara mitra dagang pun semakin baik.

Jumlah model yang diuji juga masih bertotal 120 jenis dengan hasil terbaik MAPE 8,78% , dengan parameter :

- Fungsi Aktivasi : purelin
- Fungsi Pembelajaran : trainlm
- Fungsi Pelatihan : learnngdm
- Epoch : 100
- Node : 14

Grafik 6.3 ModelVar4



Tabel 6.4 MAPE Model Variable

MODEL	MAPE
ModelVar1	9,62%
ModelVar2	9,10%
ModelVar3	18,4%
ModelVar4	8,78%

Dengan didapatkannya ModelVar4 ini sebagai model dengan nilai MAPE terkecil, maka model ini akan digunakan dan dilanjutkan pada uji coba tahap selanjutnya yaitu penentuan periode input.

6.3 Uji Periode Input

Hasil akhir yang diinginkan pada penelitian ini adalah user dapat melakukan peramalan inflasi di Indonesia untuk periode peramalan yang dapat dipilih oleh user. Dimana akan disediakan empat pilihan periode peramalan seperti yang telah diketahui. Sub-bab ini membahas hasil pengujian ModelVar4 dengan variasi periode input dan output. Pada bab ini hanya akan dijelaskan MAPE terbaik yang didapatkan untuk masing-masing model sedangkan data hasil pencarian model terbaik akan disampaikan pada lampiran C-2.

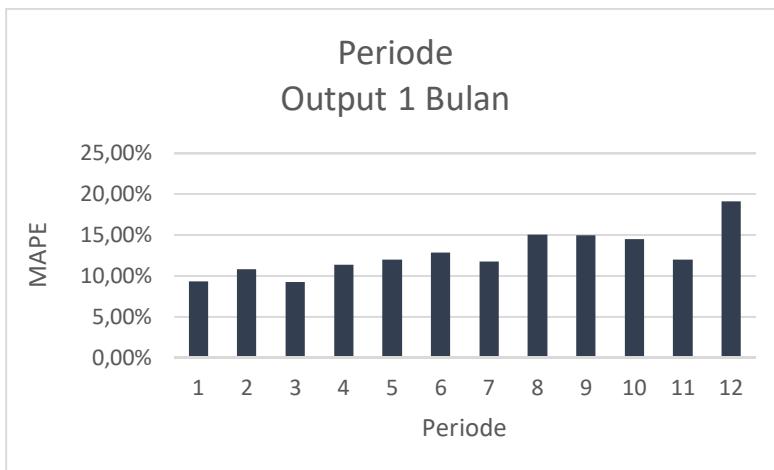
6.3.1 Periode Peramalan 1 Bulan

Pada pencarian model terbaik untuk periode output peramalan 1 bulan, akan dilakukan 12 uji coba berdasarkan jumlah periode input 1 sampai 12 bulan. Terdapat 240 model yang diuji coba pada masing-masing periode input untuk mendapatkan satu model terbaik dalam melakukan peramalan 1 periode kedepan. Terjadi penambahan pada penggunaan parameter dimana fungsi pembelajaran BGF mulai diterapkan pada pencarian model terbaik. Tabel 6.5 menunjukkan nilai MAPE dari masing-masing periode input.

Tabel 6.5 MAPE Periode Output 1

MODEL	MAPE
Input 1 Periode	9,31%
Input 2 Periode	10,76%
Input 3 Periode	9,26%

MODEL	MAPE
Input 4 Periode	11,34%
Input 5 Periode	11,99%
Input 6 Periode	12,83%
Input 7 Periode	11,74%
Input 8 Periode	14,98%
Input 9 Periode	14,96%
Input 10 Periode	14,45%
Input 11 Periode	11,95%
Input 12 Periode	19,05%



Grafik 6.4 MAPE Output 1 Bulan

Berdasarkan hasil diatas maka disimpulkan bahwa untuk melakukan peramalan dengan output 1 bulan, model input 3 bulan merupakan model terbaik dengan parameter sebagai berikut :

Node	: 3
Fungsi aktivasi	: logsig
Fungsi pembelajaran	: trainlm
Fungsi pelatihan	: learnsgdm
Epoch	: 100

Berdasarkan grafik 6.4 diatas, dapat dilihat terdapat trend error yang cenderung naik dengan bertambahnya jumlah periode input. Namun error juga terlihat turun pada bulan-bulan tertentu setelah terjadinya kenaikan untuk beberapa periode.

6.3.2 Periode Peramalan 3 Bulan

Pada pencarian model terbaik untuk periode output peramalan 3 bulan, sama seperti pencarian model peramalan 1 bulan bahwa akan dilakukan 12 uji coba berdasarkan jumlah periode input 1 sampai 12 bulan. Terdapat 240 model yang diuji coba pada masing-masing periode input untuk mendapatkan 1 model terbaik. Table di bawah menunjukkan MAPE terbaik yang didapatkan untuk masing-masing periode input

Tabel 6.6 MAPE Periode Output 3

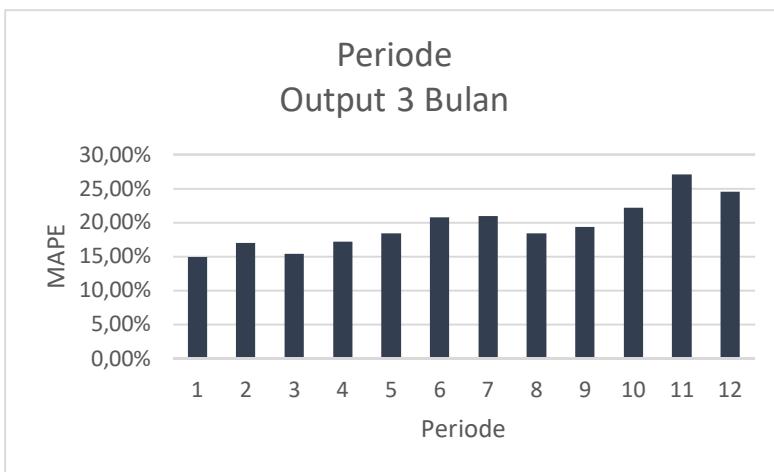
MODEL	MAPE
Input 1 Periode	14,87%
Input 2 Periode	17,00%

MODEL	MAPE
Input 3 Periode	15,38%
Input 4 Periode	17,20%
Input 5 Periode	18,42%
Input 6 Periode	20,76%
Input 7 Periode	20,94%
Input 8 Periode	18,39%
Input 9 Periode	19,31%
Input 10 Periode	22,12%
Input 11 Periode	27,02%
Input 12 Periode	24,47%

Berdasarkan hasil ujicoba pada grafik 6.5 dapat disimpulkan bahwa periode input 1 merupakan model terbaik untuk peramalan dengan output 3 bulan. Parameter yang didapatkan dari model terbaik adalah :

Node	: 18
Fungsi aktivasi	: purelin
Fungsi pembelajaran	: trainlm
Fungsi pelatihan	: learngdm
Epoch	: 100

Pada model ini, tidak seperti pada output periode 1, walaupun pada periode MAPE pada periode input ke 3 kembali terjadi penuruan, namun MAPE yang didapatkan tidak lebih baik dari periode pertama. Dan pada model ini juga ditemukan bahwa trend MAPE cenderung meningkat dengan bertambahnya jumlah periode input yang digunakan untuk peramalan.



Grafik 6.5 MAPE Output 3 Bulan

Jika dibandingkan dengan periode output 1 bulan, rata-rata MAPE untuk setiap periode input peramalan pada model ini lebih besar, sehingga dapat dikatakan bahwa dengan bertambahnya jumlah periode output peramalan, juga menghasilkan MAPE yang lebih tinggi.

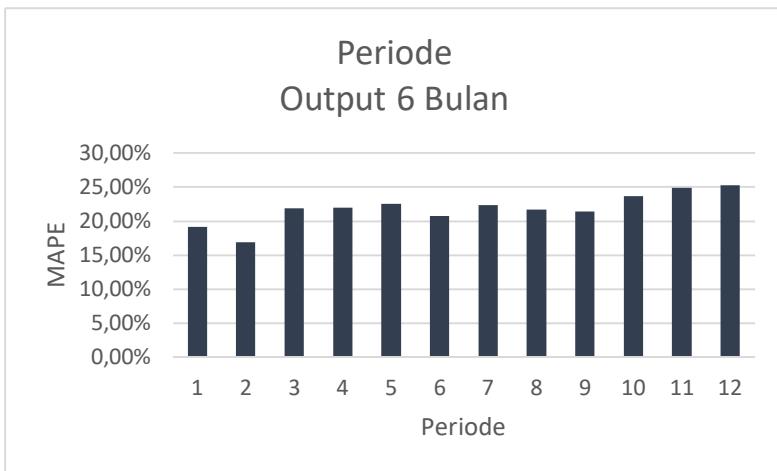
6.3.3 Periode Peramalan 6 Bulan

Pada pencarian model terbaik untuk periode output peramalan 6 bulan juga dilakukan 12 uji coba berdasarkan jumlah periode input. Terdapat 240 model yang diuji coba pada masing-masing periode

input untuk mendapatkan 1 model terbaik. Table di bawah menunjukkan MAPE terbaik yang didapatkan untuk masing-masing periode input. Sama seperti pernyataan sebelumnya pada bagian hasil uji coba periode output ke 3 dimana terjadi peningkatan rata-rata MAPE untuk jumlah periode output yang lebih banyak, pada model output 6 ini pun rata-rata MAPE yang dihasilkan juga meningkat atau lebih tinggi.

Tabel 6.7 MAPE Periode Output 6

MODEL	MAPE
Input 1 Periode	19,09%
Input 2 Periode	16,85%
Input 3 Periode	21,84%
Input 4 Periode	21,95%
Input 5 Periode	22,51%
Input 6 Periode	20,69%
Input 7 Periode	22,29%
Input 8 Periode	21,65%
Input 9 Periode	21,37%
Input 10 Periode	23,61%
Input 11 Periode	24,84%
Input 12 Periode	25,23%



Grafik 6.6 MAPE Output 6 Bulan

Berdasarkan hasil diatas, untuk periode 6 bulan, input 2 bulan merupakan model dengan akurasi peramalan yang lebih baik jika dibandingkan dengan model dengan periode input lainnya. Model terbaik tersebut didapatkan dengan parameter sebagai berikut :

Node	: 3
Fungsi aktivasi	: tansig
Fungsi pembelajaran	: trainlm
Fungsi pelatihan	: learnbgdm
Epoch	: 100

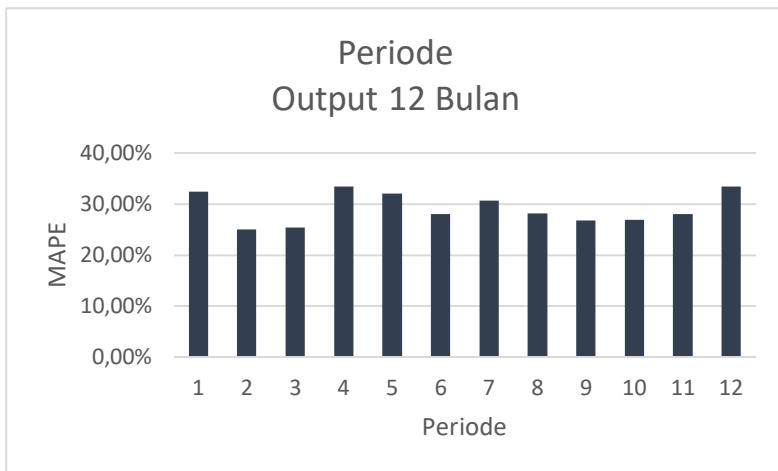
Pada model ini terdapat pola naik turun error yang berbeda dengan kedua model sebelumnya dimana pada periode ke 2 mengalami penurunan, dan periode ke 3 kembali naik. Kenaikan trend error masih terlihat namun semakin menipis atau hampir stasioner. Fungsi pembelajaran yang didapatkan untuk ketiga model terbaik baik untuk periode output 1, 3, dan 6 adalah trainlm.

6.3.4 Periode Peramalan 12 Bulan

Pada pencarian model terbaik untuk periode output peramalan 12 bulan juga dilakukan 4 uji coba berdasarkan jumlah periode input. Terdapat 240 model yang diuji coba pada masing-masing periode input untuk mendapatkan 1 model terbaik. Table di bawah menunjukkan MAPE terbaik yang didapatkan untuk masing-masing periode input

Tabel 6.8 MAPE Periode Output 12

MODEL	MAPE
Input 1 Periode	32,39%
Input 2 Periode	25,00%
Input 3 Periode	25,33%
Input 4 Periode	33,40%
Input 5 Periode	31,97%
Input 6 Periode	27,98%
Input 7 Periode	30,64%
Input 8 Periode	28,06%
Input 9 Periode	26,72%
Input 10 Periode	26,81%
Input 11 Periode	28,00%
Input 12 Periode	33,42%



Grafik 6.7 MAPE Output 12 Bulan

Berdasarkan hasil diatas dapat disimpulkan bahwa periode input 2 merupakan model terbaik untuk peramalan dengan output 12 bulan. Parameter yang didapatkan dari model terbaik adalah :

Node	: 3
Fungsi aktivasi	: logsig
Fungsi pembelajaran	: trainlm
Fungsi pelatihan	: learnrgd
Epoch	: 100

Pada model ini rata-rata MAPE yang didapatkan juga lebih besar dibandingkan dengan model-model sebelumnya. Namun pada model ini tidak terlihat adanya trend peningkatan MAPE seperti pada model-model sebelumnya. Model ini memiliki nilai MAPE yang stasioner pada nilai yang tinggi.

6.4 Kesimpulan Hasil Percobaan

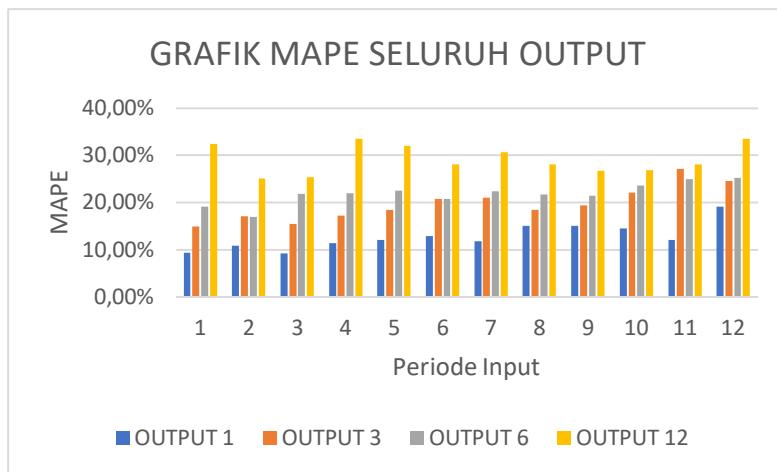
Pada bagian ini akan dilakukan penyimpulan dari hasil percobaan dengan menggunakan total 11.880 model. Pada sub-bab 6.2 telah dibahas mengenai pencarian model terbaik berdasarkan penggunaan variablenya, dan berdasarkan table 6.4 didapatkan bahwa ModelVar4 dengan variable Inflasi di Indonesia, Malaysia, Filipina dan nilai kurs rupiah. Selanjutnya pada bab 6.3 dilakukan percobaan lanjutan dengan untuk mencari periode input terbaik berdasarkan 4 periode output yang diinginkan. Table 6.9 di bawah merupakan model-model yang akan digunakan :

Tabel 6.9 Kesimpulan Penggunaan Model

Periode Peramalan	MODEL	MAPE
Output 1 Bulan	Input 3 Bulan	9,26%
Output 3 Bulan	Input 1 Bulan	14,87%
Output 6 Bulan	Input 2 Bulan	16,85%
Output 12 Bulan	Input 2 Bulan	25,00%

Berdasarkan tabel 6.9 di atas dapat dilihat bahwa MAPE terbaik yang didapatkan untuk masing-masing periode output peramalan meingkat seiring dengan bertambahnya jumlah periode output peramalan. Hal tersebut membenarkan analisa pada bagian periode output peramalan 1 dan 3. Namun sampai MAPE tertinggi pada output periode peramalan 12 bulan pun model dapat digunakan walaupun dengan tingkat akurasi yang hanya dapat dikatakan cukup.

Berdasarkan hasil uji coba juga didapatkan bahwa ternyata semakin banyak data yang digunakan untuk melakukan peramalan, dalam hal ini periode input peramalan, tidak menjadikan model yang dibuat, dapat memiliki tingkat akurasi yang lebih baik dari model dengan periode input peramalan yang sedikit.



Grafik 6.8 MAPE Seluruh Output

Grafik 6.8 diatas memperjelas bagaimana penggunaan periode input dan output peramalan yang lebih banyak cenderung memberikan MAPE yang lebih besar.

(halaman ini sengaja dikosongkan)

BAB VII

KESIMPULAN DAN SARAN

Pada bab penutup ini akan dibahas mengenai kesimpulan dari keseluruhan Tugas Akhir, dan juga saran yang dapat diberikan penulis kepada pembaca agar dapat lebih baik lagi kedepannya.

7.1 Kesimpulan

Adapun kesimpulan yang dapat diambil dari hasil uji coba yang telah dilakukan antara lain adalah :

1. *Artificial Neural Network* dapat digunakan untuk meramalkan nilai inflasi di Indonesia. Berdasarkan akurasi peramalan, untuk satu periode peramalan, ANN memberikan output yang dapat dikatakan baik dengan akurasi lebih dari 90%, namun untuk periode diatas itu, performa ANN dapat dikatakan cukup.
2. Penggunaan variable inflasi pada negara mitra dagang dan kurs nilai rupiah dapat digunakan untuk meningkatkan akurasi peramalan inflasi di Indonesia walaupun tidak memberikan peningkatan yang sangat signifikan.
3. Berdasarkan akurasi peramalan saat percobaan, dapat dikatakan bahwa semakin banyak jumlah periode yang diramalkan maka semakin tinggi pula tingkat error yang didapatkan.
4. Fungsi pembelajaran Lavenberg-Marquardt (LM) lebih cocok untuk kasus peramalan inflasi karena sebagian besar model terbaik didapatkan dengan fungsi pembelajaran ini. Disamping itu waktu *run* pencarian model juga jauh lebih singkat dengan fungsi ini.

7.2 Saran

Berikut saran yang dapat penulis sampaikan mengenai hasil penelitian pada masalah peramalan inflasi di Indonesia ini :

1. Dengan nilai MAPE yang semakin tinggi untuk periode peramalan yang lebih panjang, maka penulis menyarankan untuk menggunakan peramalan jangka pendek untuk mendapatkan akurasi peramalan terbaik, namun peramalan jangka panjang dapat dilakukan untuk melakukan analisa pola peningkatan dan penurunan nilai inflasi.
2. Untuk penelitian berikutnya dapat melakukan analisa lebih dalam, untuk menemukan variable lain yang dapat mempengaruhi hasil peramalan inflasi di Indonesia. Sehingga dapat menciptakan model yang lebih optimal dalam meramalkan inflasi di Indonesia.
3. Uji coba yang dilakukan pada penelitian berdasarkan periode peramalan, terbatas hanya pada input 1 sampai 12 bulan sedangkan mungkin model terbaik terdapat pada periode diluar periode tersebut. Hal ini dapat menjadi diteliti lebih lanjut.
4. Penggunaan nested looping pada penelitian ini dapat digunakan untuk pencarian model pada berbagai macam penelitian sejenis lainnya yang menggunakan ANN.

Daftar Pustaka

- [1] R. Dornbusch and S. Fischer, *Makroekonomi Edisi Keempat*. Jakarta: Erlangga, 1997.
- [2] W. J. Baumol and A. S. Blinder, *Economics: Principles and Policy*. 2010.
- [3] K. P. R. Indonesia, “Kemenperin: 64% dari Industri Nasional Bergantung pada Bahan Baku Impor.” [Online]. Available: <http://www.kemenperin.go.id/artikel/9306/64-dari-Industri-Nasional-Bergantung-pada-Bahan-Baku-Impor>. [Accessed: 06-Mar-2017].
- [4] Kementerian Perindustrian RI, “Industri Nasional Masih Terjajah Bahan Baku Impor.” [Online]. Available: <http://www.kemenperin.go.id/artikel/9836/Industri-Nasional-Masih-Terjajah-Bahan-Baku-Impor>. [Accessed: 25-Mar-2017].
- [5] Deutsche Welle (DW), “Komoditas Impor Terbesar Indonesia.” [Online]. Available: <http://www.dw.com/id/komoditas-impor-terbesar-indonesia/g-19444043>. [Accessed: 25-Mar-2017].
- [6] ISTIQOMAH, “Pengaruh Inflasi dan Investasi Terhadap Nilai Tukar Rupiah di Indonesia,” 2011.
- [7] “GDP Inflation | Economic Indicators of Countries.” [Online]. Available: <http://www.gdpinflation.com/>. [Accessed: 08-Mar-2017].

- [8] M. Silfiani and Suhartono, “Aplikasi Metode Ensembel untuk Peramalan Inflasi di Indonesia,” vol. 1, no. 1, pp. 1–6, 2012.
- [9] E. Nakamura, “Inflation forecasting using a neural network,” *Econ. Lett.*, vol. 86, no. 3, pp. 373–378, 2005.
- [10] Boediono, “Ekonomi Moneter,” in *Pengantar Ilmu Ekonomi*, 1985, p. 164.
- [11] A. Murni, *Ekonomika Makro*. Jakarta: PT. Refika Aditama, 2006.
- [12] N. G. Mankiw, “The reincarnation of Keynesian economics,” *Eur. Econ. Rev.*, vol. 36, no. 2–3, pp. 559–565, 1992.
- [13] Mankiw, *Mankiw Principles of Economics*, vol. 53, no. 9. 2013.
- [14] S. Pengestu, “Forecasting : Konsep dan aplikasi Edisi Kedua, Yogyakarta: BPFE,” 1986.
- [15] S. W. Makridakis, *Metode dan Aplikasi Peramalan Edisi Kedua Jilid I*. Erlangga, 1999.
- [16] B. M. Wiliamowski, T. W. Gentry, and L. R. Weatherford, “A Comparison of Traditional Forecasting.” 1995.
- [17] C. Gershenson, “Artificial Neural Networks for Beginners,” *Networks*, vol. cs.NE/0308, p. 8, 2003.
- [18] I. N. da Silva, D. Hernane Spatti, R. Andrade Flauzino, L. H. B. Liboni, and S. F. dos Reis Alves, “Artificial Neural Networks,” pp. 21–29, 2017.

- [19] M. A. Nielsen, “Neural Networks and Deep Learning.” Determination Press, 2015.
- [20] MATLAB, “Choose a Multilayer Neural Network Training Function - MATLAB & Simulink.” [Online]. Available: <https://www.mathworks.com/help/nnet/ug/choose-a-multilayer-neural-network-training-function.html>. [Accessed: 07-Jun-2017].
- [21] S. Haykin, “Neural networks-A comprehensive foundation,” *New York: IEEE Press. Herrmann, M., Bauer, H.-U., & Der, R*, vol. psychology. p. pp107-116, 1994.
- [22] A. Intelligence, “Fundamentals of Neural Networks Artificial Intelligence Fundamentals of Neural Networks Artificial Intelligence,” pp. 6–102, 2010.
- [23] R. M. Stair and G. W. Reynolds, *Principles of Information Systems*. 2009.

(halaman ini sengaja dikosongkan)

BIODATA PENULIS



Rizky Ryandhi Pakaya adalah nama lengkap penulis. Penulis lahir pada 27 Desember 1994 di Kota Jakarta. Penulis merupakan anak pertama dari tiga bersaudara. Penulis menempuh pendidikan SD di SDI Al-Azhar BSD. Penulis melanjutkan SMP di SMP Negeri 4 Kota Tangerang Selatan dan SMA di SMA Negeri 2 Tangerang Selatan dan sekarang sedang menempuh S1 di Jurusan Sistem Informasi (SI), Fakultas Teknik

Informasi (FTIf), Institut Teknologi Sepuluh Nopember (ITS) Surabaya. Penulis sempat beberapa kali ikut berpartisipasi dalam proyek dosen, dalam membangun website. Yang salah satunya adalah membangun website E-Health pemerintahan Kota Kediri. Selama masa perkuliahan di ITS, penulis lebih banyak menghabiskan waktu untuk menjalakan hobi dan kegiatan di luar kampus. Penulis juga menjadi salah satu pendiri komunitas “ITS Vaping Area” Bersama dengan sejumlah rekan lainnya, yang sampai saat ini telah memiliki ratusan member.

Penulis mengambil bidang minat Rekayasa Data dan Inteligensi Bisnis (RDIB) di Jurusan Sistem Informasi dalam menyelesaikan penelitian Tugas Akhir ini.

Email : ryandhipakaya@gmail.com

(halaman ini sengaja dikosongkan)

LAMPIRAN A

Lampiran mengenai scenario peramalan yang digunakan

Skenario 6		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none">• Tingkat inflasi di Indonesia• Tingkat inflasi di Malaysia• Tingkat inflasi di Filipina• Kurs rupiah
Output	Periode input	2 bulan
	Periode output	1 bulan

Skenario 7		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none">• Tingkat inflasi di Indonesia• Tingkat inflasi di Malaysia

Skenario 7		
Layer	Parameter	Deskripsi
		<ul style="list-style-type: none"> • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	3 bulan
	Periode output	1 bulan

Skenario 8		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	4 bulan
	Periode output	1 bulan

Skenario 9		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	5 bulan
	Periode output	1 bulan

Skenario 10		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 10		
Layer	Parameter	Deskripsi
Output	Periode input	6 bulan
	Periode output	1 bulan

Skenario 11		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	7 bulan
	Periode output	1 bulan

Skenario 12		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	8 bulan
	Periode output	1 bulan

Skenario 13		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 13		
Layer	Parameter	Deskripsi
Output	Periode input	9 bulan
	Periode output	1 bulan

Skenario 14		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	10 bulan
	Periode output	1 bulan

Skenario 15		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	11 bulan
	Periode output	1 bulan

Skenario 16		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 16		
Layer	Parameter	Deskripsi
Output	Periode input	12 bulan
	Periode output	1 bulan

Skenario 17		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	1 bulan
	Periode output	3 bulan

Skenario 18		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	2 bulan
	Periode output	3 bulan

Skenario 19		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 19		
Layer	Parameter	Deskripsi
Output	Periode input	3 bulan
	Periode output	3 bulan

Skenario 20		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	4 bulan
	Periode output	3 bulan

Skenario 21		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	5 bulan
	Periode output	3 bulan

Skenario 22		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 22		
Layer	Parameter	Deskripsi
Output	Periode input	6 bulan
	Periode output	3 bulan

Skenario 23		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	7 bulan
	Periode output	3 bulan

Skenario 24		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	8 bulan
	Periode output	3 bulan

Skenario 25		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 25		
Layer	Parameter	Deskripsi
Output	Periode input	9 bulan
	Periode output	3 bulan

Skenario 26		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	10 bulan
	Periode output	3 bulan

Skenario 27		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	11 bulan
	Periode output	3 bulan

Skenario 28		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 28		
Layer	Parameter	Deskripsi
Output	Periode input	12 bulan
	Periode output	3 bulan

Skenario 29		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	1 bulan
	Periode output	6 bulan

Skenario 30		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	2 bulan
	Periode output	6 bulan

Skenario 31		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 31		
Layer	Parameter	Deskripsi
Output	Periode input	3 bulan
	Periode output	6 bulan

Skenario 32		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	4 bulan
	Periode output	6 bulan

Skenario 33		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	5 bulan
	Periode output	6 bulan

Skenario 34		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 34		
Layer	Parameter	Deskripsi
Output	Periode input	6 bulan
	Periode output	6 bulan

Skenario 35		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	7 bulan
	Periode output	6 bulan

Skenario 36		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	8 bulan
	Periode output	6 bulan

Skenario 37		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 37		
Layer	Parameter	Deskripsi
Output	Periode input	9 bulan
	Periode output	6 bulan

Skenario 38		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	10 bulan
	Periode output	6 bulan

Skenario 39		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	11 bulan
	Periode output	6 bulan

Skenario 40		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 40		
Layer	Parameter	Deskripsi
Output	Periode input	12 bulan
	Periode output	6 bulan

Skenario 41		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	1 bulan
	Periode output	12 bulan

Skenario 42		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	2 bulan
	Periode output	12 bulan

Skenario 43		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 43		
Layer	Parameter	Deskripsi
Output	Periode input	3 bulan
	Periode output	12 bulan

Skenario 44		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	4 bulan
	Periode output	12 bulan

Skenario 45		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	5 bulan
	Periode output	12 bulan

Skenario 46		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 46		
Layer	Parameter	Deskripsi
Output	Periode input	6 bulan
	Periode output	12 bulan

Skenario 47		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	7 bulan
	Periode output	12 bulan

Skenario 48		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	8 bulan
	Periode output	12 bulan

Skenario 49		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 49		
Layer	Parameter	Deskripsi
Output	Periode input	9 bulan
	Periode output	12 bulan

Skenario 50		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	10 bulan
	Periode output	12 bulan

Skenario 51		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah
Output	Periode input	11 bulan
	Periode output	12 bulan

Skenario 52		
Layer	Parameter	Deskripsi
Input Layer	Variable	<ul style="list-style-type: none"> • Tingkat inflasi di Indonesia • Tingkat inflasi di Malaysia • Tingkat inflasi di Filipina • Kurs rupiah

Skenario 52		
Layer	Parameter	Deskripsi
Output	Periode input	12 bulan
	Periode output	12 bulan

LAMPIRAN B

Data yang digunakan dalam penelitian

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Jan '95	9,53%	3,50%	2,60%	4,90%	5,80%	24,10%	2,80%	0,50%	2217,0
Feb '95	9,03%	3,10%	2,40%	4,80%	5,00%	22,40%	2,86%	0,20%	2216,5
Mar '95	8,91%	3,30%	2,60%	4,70%	5,60%	21,30%	2,85%	- 0,30%	2238,0
Apr '95	10,48%	3,30%	2,30%	5,30%	5,60%	20,70%	3,05%	- 0,20%	2233,0
Mei '95	10,46%	3,80%	2,20%	5,40%	6,30%	20,30%	3,19%	- 0,10%	2226,5
Jun '95	10,50%	3,90%	1,80%	5,40%	6,60%	18,20%	3,04%	0,20%	2227,0
Jul '95	9,76%	3,80%	1,50%	5,60%	6,40%	16,70%	2,76%	0,10%	2235,0
Ag5 '95	9,14%	3,80%	1,40%	6,00%	6,80%	14,50%	2,62%	- 0,20%	2266,5
Sep '95	8,99%	2,80%	1,30%	6,00%	8,80%	13,20%	2,54%	0,10%	2265,5
Okt '95	8,71%	3,40%	1,10%	6,50%	8,80%	12,10%	2,81%	- 0,70%	2271,0
Nov '95	8,66%	3,40%	0,90%	7,20%	8,10%	11,20%	2,61%	- 0,70%	2283,5
Des '95	8,98%	3,30%	0,80%	7,40%	8,10%	10,10%	2,54%	- 0,40%	2286,5

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Jan '96	11,07%	3,40%	0,90%	7,40%	8,50%	9,00%	2,73%	- 0,50%	2292,0
Feb '96	11,08%	3,40%	1,60%	7,50%	8,70%	9,30%	2,65%	- 0,40%	2316,5
Mar '96	9,71%	3,20%	1,50%	7,50%	8,70%	9,80%	2,84%	0,10%	2338,0
Apr '96	8,20%	3,60%	1,10%	7,00%	8,90%	9,70%	2,90%	0,20%	2328,5
Mei '96	8,37%	3,60%	1,20%	6,20%	8,00%	8,90%	2,89%	0,20%	2332,5
Jun '96	7,39%	3,80%	1,20%	5,60%	8,00%	8,60%	2,75%	0,00%	2326,5
Jul '96	7,38%	3,50%	1,30%	5,40%	7,80%	8,30%	2,95%	0,40%	2352,5
Ags '96	6,99%	3,30%	1,40%	5,60%	7,30%	8,10%	2,88%	0,20%	2342,0
Sep '96	6,79%	4,20%	1,50%	4,60%	5,30%	7,40%	3,00%	0,00%	2322,8
Okt '96	6,53%	3,40%	1,40%	4,30%	5,40%	7,00%	2,99%	0,50%	2329,3
Nov '96	6,53%	3,30%	1,40%	4,80%	6,50%	6,90%	3,26%	0,50%	2345,0
Des '96	6,04%	3,30%	2,00%	4,80%	6,90%	7,00%	3,32%	0,60%	2362,0
Jan '97	4,61%	3,20%	1,90%	4,30%	5,60%	5,90%	3,04%	0,60%	2376,5

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Feb '97	4,03%	3,10%	1,60%	4,30%	5,30%	5,60%	3,03%	0,60%	2396,5
Mar '97	4,75%	3,20%	1,60%	4,50%	5,40%	4,00%	2,76%	0,50%	2401,0
Apr '97	4,86%	2,60%	1,90%	4,10%	5,10%	3,20%	2,50%	2,00%	2430,0
Mei '97	4,51%	2,50%	1,60%	4,20%	5,00%	2,80%	2,23%	2,00%	2433,5
Jun '97	5,25%	2,20%	1,70%	4,50%	5,60%	2,80%	2,30%	2,30%	2431,5
Jul '97	5,37%	2,10%	2,10%	4,90%	5,40%	2,70%	2,23%	2,00%	2615,0
Ags '97	6,38%	2,40%	2,30%	6,60%	5,30%	1,90%	2,23%	2,20%	2935,0
Sep '97	7,34%	2,30%	2,50%	6,90%	5,80%	1,80%	2,15%	2,50%	3270,0
Okt '97	8,40%	2,70%	2,50%	7,20%	5,90%	1,50%	2,08%	2,60%	3600,0
Nov '97	8,81%	2,60%	2,30%	7,60%	6,40%	1,10%	1,83%	2,20%	3660,0
Des '97	10,31%	2,90%	2,00%	7,60%	6,20%	0,40%	1,70%	1,90%	5550,0
Jan '98	16,25%	3,40%	1,50%	8,60%	6,50%	0,30%	1,57%	1,90%	10050,0
Feb '98	29,99%	4,40%	0,90%	8,90%	7,60%	-0,10%	1,44%	2,00%	8950,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Mar '98	36,80%	5,10%	0,90%	9,50%	8,10%	0,70%	1,37%	2,30%	8700,0
Apr '98	42,65%	5,60%	0,50%	10,20%	8,30%	-0,30%	1,44%	0,40%	8000,0
Mei '98	49,67%	5,40%	0,10%	10,20%	9,70%	-1,00%	1,69%	0,50%	11450,0
Jun '98	56,67%	6,20%	-0,20%	10,60%	10,00%	-1,30%	1,68%	0,10%	14800,0
Jul '98	68,72%	5,80%	-0,50%	10,00%	10,10%	-1,40%	1,68%	-0,10%	13150,0
Ags '98	77,72%	5,60%	-1,00%	7,70%	9,90%	-1,40%	1,62%	-0,30%	11050,0
Sep '98	82,40%	5,50%	-1,30%	7,00%	9,90%	-1,50%	1,49%	-0,20%	10700,0
Okt '98	79,41%	5,20%	-1,50%	5,90%	9,80%	-1,10%	1,49%	0,20%	7600,0
Nov '98	78,15%	5,60%	-1,30%	4,70%	10,70%	-1,20%	1,55%	0,80%	7437,5
Des '98	77,63%	5,30%	-1,40%	4,30%	10,00%	-1,00%	1,61%	0,60%	8000,0
Jan '99	70,66%	5,20%	-0,90%	3,50%	10,50%	-1,20%	1,67%	0,20%	8850,0
Feb '99	53,39%	3,80%	-0,70%	2,90%	9,00%	-1,30%	1,61%	-0,10%	8800,0
Mar '99	45,44%	3,10%	-0,50%	1,50%	7,70%	-1,80%	1,73%	-0,40%	8650,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Apr '99	37,97%	2,90%	-0,30%	0,40%	7,10%	-2,20%	2,28%	-0,10%	8017,5
Mei '99	30,73%	2,90%	0,10%	-0,50%	5,80%	-2,20%	2,09%	-0,40%	8115,0
Jun '99	24,52%	2,20%	0,10%	-1,20%	4,90%	-2,10%	1,96%	-0,30%	6705,0
Jul '99	13,49%	2,50%	0,20%	-1,10%	4,80%	-1,40%	2,14%	-0,10%	6880,0
Ags '99	5,77%	2,30%	0,40%	-1,10%	4,70%	-1,30%	2,26%	0,30%	7675,0
Sep '99	1,25%	2,20%	0,40%	-0,80%	4,90%	-0,80%	2,63%	-0,20%	8300,0
Okt '99	1,58%	2,10%	0,50%	-0,40%	5,00%	-0,60%	2,56%	-0,70%	6825,0
Nov '99	1,60%	1,60%	0,40%	0,00%	3,60%	-0,90%	2,62%	-1,10%	7315,0
Des '99	1,92%	2,50%	0,70%	0,70%	3,90%	-1,00%	2,68%	-1,10%	6987,5
Jan '00	0,28%	1,60%	0,90%	0,61%	2,20%	-0,20%	2,74%	-0,70%	7445,0
Feb '00	-0,89%	1,50%	1,30%	0,97%	2,50%	0,70%	3,22%	-0,60%	7435,0
Mar '00	-1,17%	1,60%	1,20%	1,22%	2,80%	-0,20%	3,76%	-0,50%	7570,0
Apr '00	0,07%	1,50%	1,10%	1,10%	3,30%	-0,30%	3,07%	-0,80%	7925,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Mei '00	1,20%	1,30%	0,50%	1,71%	3,40%	0,10%	3,19%	- 0,70%	8645,0
Jun '00	2,04%	1,40%	0,80%	2,08%	3,80%	0,50%	3,73%	- 0,60%	8760,0
Jul '00	4,45%	1,40%	1,20%	1,83%	4,20%	0,50%	3,66%	- 0,50%	8925,0
Ags '00	5,97%	1,50%	1,60%	2,07%	4,40%	0,30%	3,41%	- 0,50%	8325,0
Sep '00	6,64%	1,50%	1,70%	2,43%	4,20%	0,00%	3,45%	- 0,90%	8760,0
Okt '00	7,82%	1,90%	1,80%	1,82%	4,60%	0,00%	3,45%	- 1,10%	9347,5
Nov '00	9,12%	1,80%	2,00%	1,82%	5,70%	1,30%	3,45%	- 0,80%	9530,0
Des '00	9,35%	1,20%	2,10%	1,45%	6,50%	1,50%	3,39%	- 0,40%	9675,0
Jan '01	8,28%	1,50%	2,00%	1,33%	7,50%	1,20%	3,73%	- 0,30%	9450,0
Feb '01	9,12%	1,60%	1,30%	1,44%	7,40%	0,00%	3,53%	- 0,40%	9865,0
Mar '01	10,60%	1,50%	1,80%	1,44%	7,60%	0,80%	2,92%	- 0,80%	10417,5
Apr '01	10,51%	1,60%	2,00%	2,53%	7,40%	1,60%	3,27%	- 0,80%	11600,0
Mei '01	10,82%	1,60%	1,90%	2,77%	7,40%	1,70%	3,62%	- 0,80%	11125,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Jun '01	12,11%	1,50%	1,20%	2,16%	7,20%	1,40%	3,25%	- 0,90%	11390,0
Jul '01	13,04%	1,40%	1,30%	2,16%	7,40%	1,50%	2,72%	- 0,90%	9500,0
Ags '01	12,23%	1,30%	0,70%	1,43%	7,00%	1,00%	2,72%	- 0,80%	8862,5
Sep '01	13,01%	1,40%	0,50%	1,30%	6,80%	-0,10%	2,65%	- 0,90%	9707,5
Okt '01	12,47%	0,90%	0,20%	1,31%	6,10%	0,20%	2,13%	- 0,90%	10475,0
Nov '01	12,91%	1,50%	- 0,20%	0,95%	5,00%	-0,30%	1,90%	- 1,10%	10465,0
Des '01	12,55%	1,20%	- 0,60%	0,72%	4,50%	-0,30%	1,55%	- 1,30%	10400,0
Jan '02	14,56%	1,10%	- 1,10%	0,83%	3,70%	-1,00%	1,14%	- 1,50%	10315,0
Feb '02	14,88%	1,20%	- 0,60%	0,36%	3,20%	0,00%	1,14%	- 1,60%	10150,0
Mar '02	14,21%	2,10%	- 0,90%	0,59%	3,50%	-0,80%	1,48%	- 1,20%	9825,0
Apr '02	13,44%	1,90%	- 1,10%	0,47%	3,50%	1,30%	1,64%	- 1,10%	9330,0
Mei '02	13,09%	1,90%	- 0,30%	0,23%	3,50%	-1,10%	1,18%	- 0,90%	8697,5
Jun '02	11,57%	2,10%	- 0,10%	0,35%	2,90%	-0,80%	1,07%	- 0,70%	8713,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Jul '02	10,02%	2,10%	- 0,40%	0,24%	2,60%	-0,90%	1,46%	- 0,80%	9064,5
Ags '02	10,58%	2,10%	- 0,40%	0,35%	3,00%	-0,70%	1,80%	- 0,90%	8855,0
Sep '02	10,54%	2,10%	- 0,40%	0,47%	2,70%	-0,70%	1,51%	- 0,70%	8994,0
Okt '02	10,34%	2,10%	- 0,20%	1,53%	2,60%	-0,80%	2,03%	- 0,90%	9230,0
Nov '02	10,41%	1,60%	0,20%	1,30%	2,40%	-0,70%	2,20%	- 0,40%	8977,5
Des '02	9,92%	1,70%	0,40%	1,66%	2,50%	-0,40%	2,38%	- 0,30%	8950,0
Jan '03	8,66%	1,70%	0,90%	2,24%	2,80%	0,40%	2,60%	- 0,40%	8870,0
Feb '03	7,65%	1,60%	0,40%	2,00%	3,20%	0,20%	2,98%	- 0,20%	8883,5
Mar '03	7,11%	0,70%	0,80%	1,76%	3,00%	0,90%	3,02%	- 0,10%	8901,5
Apr '03	7,64%	1,00%	0,90%	1,52%	3,30%	1,00%	2,22%	- 0,10%	8673,5
Mei '03	7,07%	1,00%	- 0,10%	1,87%	3,40%	0,70%	2,06%	- 0,20%	8310,0
Jun '03	6,95%	0,80%	- 0,30%	1,64%	3,90%	0,30%	2,11%	- 0,40%	8250,0
Jul '03	6,20%	1,00%	0,30%	1,76%	3,70%	0,50%	2,11%	- 0,20%	8510,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Ags '03	6,58%	1,00%	0,50%	2,22%	3,40%	0,90%	2,16%	- 0,30%	8485,0
Sep '03	6,34%	1,10%	0,70%	1,75%	3,60%	1,10%	2,32%	- 0,20%	8395,0
Okt '03	6,41%	1,30%	0,60%	1,28%	3,60%	1,80%	2,04%	0,00%	8496,5
Nov '03	5,52%	1,10%	0,60%	1,86%	3,90%	3,00%	1,77%	- 0,50%	8505,0
Des '03	5,17%	1,20%	0,70%	1,75%	3,90%	3,20%	1,88%	- 0,40%	8422,5
Jan '04	4,84%	1,00%	0,70%	1,27%	4,10%	3,20%	1,93%	- 0,30%	8458,5
Feb '04	4,55%	0,90%	2,00%	2,20%	4,00%	2,10%	1,69%	0,00%	8455,0
Mar '04	5,12%	1,00%	1,00%	2,31%	4,20%	3,00%	1,74%	- 0,10%	8563,5
Apr '04	5,87%	1,00%	1,50%	2,53%	4,30%	3,80%	2,29%	- 0,40%	8783,0
Mei '04	6,51%	1,20%	2,40%	2,41%	4,50%	4,40%	3,27%	- 0,50%	9267,5
Jun '04	6,78%	1,30%	1,90%	3,11%	5,40%	5,00%	3,05%	0,00%	9395,0
Jul '04	7,25%	1,30%	2,00%	3,23%	6,60%	5,30%	2,99%	- 0,10%	9142,0
Ags '04	6,64%	1,40%	1,80%	3,09%	6,80%	5,30%	2,65%	- 0,20%	9367,5

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Sep '04	6,24%	1,60%	1,90%	3,56%	7,20%	5,20%	2,54%	0,00%	9149,5
Okt '04	6,21%	2,10%	1,90%	3,44%	7,70%	4,30%	3,19%	0,50%	9087,5
Nov '04	6,24%	2,20%	1,80%	2,97%	8,20%	2,90%	3,52%	0,80%	9000,0
Des '04	6,47%	2,10%	1,30%	2,97%	8,60%	2,40%	3,26%	0,20%	9282,5
Jan '05	7,24%	2,40%	0,40%	2,74%	8,40%	1,90%	2,97%	0,20%	9165,0
Feb '05	7,16%	2,40%	0,00%	2,49%	8,50%	4,00%	3,01%	- 0,10%	9264,5
Mar '05	8,84%	2,50%	0,40%	3,28%	8,50%	2,70%	3,15%	0,00%	9471,0
Apr '05	8,13%	2,50%	0,40%	3,48%	8,50%	1,80%	3,51%	0,10%	9570,0
Mei '05	7,40%	3,00%	0,00%	3,70%	8,50%	1,80%	2,80%	0,10%	9518,0
Jun '05	7,46%	3,10%	- 0,20%	3,80%	7,60%	1,60%	2,53%	- 0,50%	9760,0
Jul '05	7,82%	3,00%	0,10%	5,36%	7,10%	1,80%	3,17%	- 0,30%	9805,0
Ags '05	8,32%	3,70%	0,70%	5,56%	7,20%	1,30%	3,64%	- 0,30%	10300,0
Sep '05	9,06%	3,50%	0,60%	5,98%	7,00%	0,90%	4,69%	- 0,30%	10300,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Okt '05	17,93%	3,10%	1,10%	6,31%	7,00%	1,20%	4,35%	- 0,80%	10122,5
Nov '05	18,34%	3,30%	1,00%	5,89%	7,10%	1,30%	3,46%	- 1,00%	10025,0
Des '05	17,07%	3,20%	1,30%	5,78%	6,70%	1,60%	3,42%	- 0,40%	9830,0
Jan '06	17,06%	3,30%	1,70%	5,88%	5,90%	1,90%	3,99%	- 0,10%	9370,0
Feb '06	17,95%	3,20%	1,20%	5,52%	6,50%	0,90%	3,60%	- 0,10%	9182,5
Mar '06	15,73%	4,80%	1,20%	5,69%	6,60%	0,80%	3,36%	- 0,20%	9087,0
Apr '06	15,40%	4,60%	1,10%	6,08%	6,30%	1,20%	3,55%	- 0,10%	8785,0
Mei '06	15,60%	3,90%	1,10%	6,26%	6,00%	1,40%	4,17%	0,10%	9255,0
Jun '06	15,53%	3,90%	1,40%	5,92%	5,90%	1,50%	4,32%	0,50%	9263,0
Jul '06	15,15%	4,10%	1,10%	4,34%	5,50%	1,00%	4,15%	0,30%	9095,0
Ags '06	14,90%	3,30%	0,70%	3,79%	5,20%	1,30%	3,82%	0,90%	9117,0
Sep '06	14,55%	3,30%	0,40%	2,72%	4,90%	1,50%	2,06%	0,60%	9205,0
Okt '06	6,29%	3,10%	0,40%	2,81%	4,70%	1,40%	1,31%	0,40%	9094,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Nov '06	5,27%	3,00%	0,50%	3,46%	4,20%	1,90%	1,97%	0,30%	9165,0
Des '06	6,60%	3,10%	0,80%	3,47%	4,10%	2,80%	2,54%	0,30%	8993,5
Jan '07	6,26%	3,20%	- 0,60%	3,04%	3,80%	2,20%	2,08%	0,00%	9100,0
Feb '07	6,30%	3,10%	- 0,10%	2,41%	2,90%	2,70%	2,42%	- 0,20%	9131,5
Mar '07	6,52%	1,60%	0,20%	1,97%	2,60%	3,30%	2,78%	- 0,10%	9120,0
Apr '07	6,29%	1,60%	0,40%	1,84%	2,60%	3,00%	2,57%	0,00%	9088,0
Mei '07	6,01%	1,50%	1,30%	1,93%	2,60%	3,40%	2,69%	0,00%	8827,0
Jun '07	5,78%	1,40%	1,70%	1,93%	2,70%	4,40%	2,69%	- 0,20%	9035,0
Jul '07	6,06%	1,60%	3,00%	1,83%	2,90%	5,60%	2,36%	0,00%	9225,0
Ags '07	6,51%	1,90%	3,50%	1,12%	2,70%	6,50%	1,97%	- 0,20%	9390,0
Sep '07	6,95%	1,80%	3,00%	2,03%	2,90%	6,20%	2,76%	- 0,20%	9145,0
Okt '07	6,88%	1,90%	4,10%	2,53%	2,90%	6,50%	3,54%	0,30%	9097,5
Nov '07	6,71%	2,30%	4,90%	3,04%	3,10%	6,90%	4,31%	0,60%	9370,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Des '07	6,59%	2,40%	3,70%	3,25%	3,80%	6,50%	4,08%	0,70%	9392,5
Jan '08	7,36%	2,30%	6,60%	4,27%	4,60%	7,10%	4,28%	0,70%	9246,5
Feb '08	7,40%	2,70%	6,50%	5,41%	5,10%	8,70%	4,03%	1,00%	9065,0
Mar '08	8,17%	2,80%	6,70%	5,38%	5,90%	8,30%	3,98%	1,20%	9215,0
Apr '08	8,96%	3,10%	7,50%	6,13%	7,30%	8,50%	3,94%	0,80%	9222,0
Mei '08	10,38%	3,80%	7,50%	7,58%	8,30%	7,70%	4,18%	1,30%	9315,0
Jun '08	11,28%	7,70%	7,50%	8,77%	9,40%	7,10%	5,02%	2,00%	9220,0
Jul '08	12,01%	8,50%	6,50%	9,17%	10,20%	6,30%	5,60%	2,30%	9095,0
Ags '08	11,74%	8,50%	6,40%	6,52%	10,50%	4,90%	5,37%	2,10%	9150,0
Sep '08	11,93%	8,20%	6,70%	6,08%	10,10%	4,60%	4,94%	2,10%	9415,0
Okt '08	11,55%	7,60%	6,40%	3,85%	9,70%	4,00%	3,66%	1,70%	10900,0
Nov '08	11,48%	5,70%	5,50%	2,17%	9,00%	2,40%	1,07%	1,00%	12025,0
Des '08	10,23%	4,40%	5,50%	0,39%	7,70%	1,20%	0,09%	0,40%	10900,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Jan '09	8,24%	3,90%	4,30%	-0,39%	7,00%	1,00%	0,03%	0,00%	11380,0
Feb '09	7,76%	3,70%	3,30%	-0,10%	7,20%	-1,60%	0,24%	- 0,10%	11980,0
Mar '09	6,98%	3,50%	2,60%	-0,19%	6,50%	-1,20%	- 0,38%	- 0,30%	11555,0
Apr '09	6,04%	3,10%	0,30%	-0,95%	5,60%	-1,50%	- 0,74%	- 0,10%	10585,0
Mei '09	4,62%	2,40%	0,20%	-3,34%	4,40%	-1,40%	- 1,28%	- 1,10%	10290,0
Jun '09	3,65%	- 1,40%	0,00%	-4,03%	3,10%	-1,70%	- 1,43%	- 1,80%	10207,5
Jul '09	2,71%	- 2,40%	- 0,30%	-4,38%	2,10%	-1,80%	- 2,10%	- 2,20%	9925,0
Ags '09	2,76%	- 2,40%	- 0,30%	-1,04%	1,70%	-1,20%	- 1,48%	- 2,20%	10080,0
Sep '09	2,83%	- 2,00%	- 0,50%	-1,03%	2,20%	-0,80%	- 1,29%	- 2,20%	9645,0
Okt '09	2,57%	- 1,50%	- 0,90%	0,38%	2,80%	-0,50%	- 0,18%	- 2,50%	9550,0
Nov '09	2,41%	- 0,10%	- 0,80%	1,93%	3,60%	0,60%	1,84%	- 1,90%	9455,0
Des '09	2,78%	1,10%	- 0,50%	3,53%	4,50%	1,90%	2,72%	- 1,70%	9425,0
Jan '10	3,72%	1,30%	0,20%	4,10%	3,90%	1,50%	2,63%	- 0,10%	9350,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Feb '10	3,82%	1,20%	1,00%	3,67%	3,90%	2,70%	2,14%	- 0,80%	9337,0
Mar '10	3,43%	1,30%	1,60%	3,41%	4,00%	2,40%	2,31%	- 0,80%	9090,0
Apr '10	3,91%	1,50%	3,20%	2,93%	4,00%	2,80%	2,24%	- 0,80%	9012,5
Mei '10	4,16%	1,60%	3,20%	3,42%	3,70%	3,10%	2,02%	- 0,70%	9175,0
Jun '10	5,05%	1,60%	2,70%	3,30%	3,70%	2,90%	1,05%	- 0,70%	9060,0
Jul '10	6,22%	1,80%	3,10%	3,46%	3,70%	3,30%	1,24%	- 1,00%	8940,0
Ags '10	6,44%	1,90%	3,30%	3,30%	4,00%	3,50%	1,15%	- 1,10%	9035,0
Sep '10	5,80%	1,70%	3,70%	3,03%	3,90%	3,60%	1,14%	- 0,90%	8925,0
Okt '10	5,67%	1,80%	3,50%	2,86%	3,30%	4,40%	1,17%	- 0,20%	8937,5
Nov '10	6,33%	1,80%	3,80%	2,80%	3,70%	5,10%	1,14%	- 0,30%	9034,0
Des '10	6,96%	2,00%	4,60%	3,00%	3,60%	4,60%	1,50%	- 0,40%	9010,0
Jan '11	7,02%	2,40%	5,50%	3,03%	4,00%	4,90%	1,63%	- 0,60%	9048,0
Feb '11	6,83%	2,90%	5,00%	2,87%	4,70%	4,90%	2,11%	- 0,50%	8821,5

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Mar '11	6,65%	3,00%	5,00%	3,14%	4,90%	5,40%	2,68%	- 0,50%	8707,5
Apr '11	6,16%	3,20%	4,50%	4,04%	4,70%	5,30%	3,16%	- 0,50%	8564,0
Mei '11	5,98%	3,30%	4,50%	4,19%	4,90%	5,50%	3,57%	- 0,40%	8535,5
Jun '11	5,54%	3,50%	5,20%	4,06%	5,20%	6,40%	3,56%	- 0,40%	8576,5
Jul '11	4,61%	3,40%	5,40%	4,08%	4,90%	6,50%	3,63%	0,20%	8500,0
Ags '11	4,79%	3,30%	5,70%	4,29%	4,60%	6,20%	3,77%	0,20%	8533,0
Sep '11	4,61%	3,40%	5,50%	4,03%	4,70%	6,10%	3,87%	0,00%	8790,0
Okt '11	4,42%	3,40%	5,40%	4,19%	5,20%	5,50%	3,53%	- 0,20%	8852,5
Nov '11	4,15%	3,30%	5,70%	4,19%	4,70%	4,20%	3,39%	- 0,50%	9110,0
Des '11	3,79%	3,00%	5,50%	3,53%	4,20%	4,10%	2,96%	- 0,20%	9067,5
Jan '12	3,65%	2,70%	4,80%	3,38%	4,00%	4,50%	2,93%	0,10%	8990,0
Feb '12	3,56%	2,20%	4,60%	3,35%	2,70%	3,20%	2,87%	0,30%	9020,0
Mar '12	3,97%	2,10%	5,20%	3,45%	2,60%	3,60%	2,65%	0,50%	9144,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Apr '12	4,50%	1,90%	5,40%	2,47%	3,00%	3,40%	2,30%	0,50%	9190,5
Mei '12	4,45%	1,80%	5,00%	2,53%	3,00%	3,00%	1,70%	0,20%	9400,0
Jun '12	4,53%	1,60%	5,30%	2,56%	2,80%	2,20%	1,66%	- 0,10%	9392,5
Jul '12	4,56%	1,40%	4,00%	2,73%	3,20%	1,80%	1,41%	- 0,40%	9445,0
Ags '12	4,58%	1,40%	3,90%	2,69%	3,80%	2,00%	1,69%	- 0,50%	9535,0
Sep '12	4,31%	1,40%	4,70%	3,38%	3,70%	1,90%	1,99%	- 0,30%	9570,0
Okt '12	4,61%	1,40%	4,00%	3,32%	3,20%	1,70%	2,16%	- 0,40%	9605,0
Nov '12	4,32%	1,30%	3,60%	2,74%	2,80%	2,00%	1,76%	- 0,20%	9593,5
Des '12	4,30%	1,20%	4,30%	3,63%	3,00%	2,50%	1,74%	- 0,10%	9637,5
Jan '13	4,57%	1,30%	3,60%	3,39%	3,10%	2,00%	1,59%	- 0,30%	9697,5
Feb '13	5,31%	1,50%	4,90%	3,23%	3,40%	3,20%	1,98%	- 0,70%	9663,5
Mar '13	5,90%	1,60%	3,50%	2,69%	3,20%	2,10%	1,47%	- 0,90%	9717,5
Apr '13	5,57%	1,70%	1,50%	2,42%	2,60%	2,40%	1,06%	- 0,70%	9722,5

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Mei '13	5,47%	1,80%	1,60%	2,27%	2,60%	2,10%	1,36%	- 0,30%	9795,0
Jun '13	5,90%	1,80%	1,80%	2,25%	2,70%	2,70%	1,75%	0,20%	9925,0
Jul '13	8,61%	2,00%	1,90%	205%	2,50%	2,70%	1,96%	0,70%	10277,5
Ags '13	8,79%	1,90%	2,00%	1,59%	2,10%	2,60%	1,52%	0,90%	10920,0
Sep '13	8,40%	2,57%	1,60%	1,42%	2,70%	3,10%	1,18%	1,10%	11580,0
Okt '13	8,32%	2,75%	2,00%	1,46%	2,90%	3,20%	0,96%	1,10%	11272,5
Nov '13	8,37%	2,94%	2,60%	1,92%	3,35%	3,00%	1,24%	1,60%	11962,5
Des '13	8,38%	3,22%	1,48%	1,67%	4,18%	2,50%	1,50%	1,60%	12170,0
Jan '14	8,22%	3,40%	1,39%	1,93%	4,24%	2,50%	1,58%	1,41%	12210,0
Feb '14	7,75%	3,49%	0,34%	1,96%	4,08%	2,00%	1,13%	1,51%	11609,0
Mar '14	7,32%	3,48%	1,21%	2,11%	3,92%	2,40%	1,51%	1,61%	11360,0
Apr '14	7,25%	3,39%	2,54%	2,45%	4,14%	1,80%	1,95%	3,41%	11561,5
Mei '14	7,32%	3,19%	2,71%	2,62%	4,51%	2,30%	2,13%	3,71%	11675,0

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Jun '14	6,70%	3,28%	1,83%	2,35%	4,41%	2,30%	2,07%	3,61%	11855,0
Jul '14	4,53%	3,18%	1,22%	2,16%	4,85%	2,30%	1,99%	3,40%	11577,5
Ags '14	3,99%	3,27%	0,86%	2,09%	4,92%	2,00%	1,70%	3,29%	11690,0
Sep '14	4,53%	2,59%	0,60%	1,75%	4,37%	1,60%	1,66%	3,28%	12185,0
Okt '14	4,83%	2,77%	0,03%	1,48%	4,29%	1,60%	1,66%	2,88%	12085,0
Nov '14	6,23%	3,04%	- 0,34%	1,26%	3,68%	1,40%	1,32%	2,38%	12204,0
Des '14	8,36%	2,66%	- 0,17%	0,61%	2,70%	1,50%	0,76%	2,38%	12385,0
Jan '15	6,96%	1,00%	- 0,40%	-0,41%	2,40%	0,80%	- 0,09%	2,38%	12667,5
Feb '15	6,29%	0,09%	- 0,30%	-0,52%	2,47%	1,40%	- 0,03%	2,18%	12925,0
Mar '15	6,38%	0,91%	- 0,40%	-0,57%	2,40%	1,40%	- 0,07%	2,28%	13075,0
Apr '15	6,79%	1,82%	- 0,50%	-1,04%	2,17%	1,50%	- 0,20%	0,58%	12962,5
Mei '15	7,15%	2,09%	- 0,40%	-1,27%	1,58%	1,20%	0,04%	0,48%	13224,0
Jun '15	7,26%	2,54%	- 0,30%	-1,07%	1,22%	1,40%	0,12%	0,39%	13332,5

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Jul '15	7,26%	3,26%	- 0,40%	-1,05%	0,85%	1,60%	0,17%	0,29%	13527,5
Ag5 '15	7,18%	3,08%	- 0,80%	-1,19%	0,64%	2,00%	0,20%	0,19%	14050,0
Sep '15	6,83%	2,62%	- 0,60%	-1,07%	0,36%	1,60%	- 0,04%	0,00%	14650,0
Okt '15	6,25%	2,52%	- 0,80%	-0,77%	0,42%	1,30%	0,17%	0,29%	13687,5
Nov '15	4,89%	2,59%	- 0,70%	-0,97%	1,07%	1,50%	0,50%	0,29%	13835,0
Des '15	3,35%	2,68%	- 0,60%	-0,85%	1,49%	1,60%	0,73%	0,19%	13787,5
Jan '16	4,14%	3,53%	- 0,60%	-0,53%	1,35%	1,80%	1,37%	- 0,10%	13775,0
Feb '16	4,42%	4,18%	- 0,80%	-0,50%	0,92%	2,30%	1,02%	0,29%	13372,0
Mar '16	4,45%	2,61%	- 1,00%	-0,46%	1,13%	2,30%	0,85%	0,00%	13260,0
Apr '16	3,60%	2,14%	- 0,40%	0,07%	1,13%	2,30%	1,12%	- 0,30%	13185,0
Mei '16	3,33%	2,05%	- 1,60%	0,46%	1,56%	2,00%	1,02%	- 0,38%	13660,0
Jun '16	3,45%	1,59%	- 0,80%	0,38%	1,91%	1,90%	1,00%	- 0,48%	13212,5
Jul '16	3,21%	1,05%	- 0,70%	0,10%	1,91%	1,80%	0,84%	- 0,40%	13098,5

	Indo	Malay	Spore	Thai	Phil	China	US	Japan	Kursa
Ags '16	2,79%	1,49%	- 0,20%	0,29%	1,84%	1,30%	1,06%	- 0,50%	13267,5
Sep '16	3,07%	1,49%	- 0,20%	0,38%	2,26%	1,90%	1,46%	- 0,50%	13051,0
Okt '16	3,31%	1,40%	- 0,10%	0,34%	2,33%	2,10%	1,64%	0,10%	13048,0
Nov '16	3,58%	1,83%	0,00%	0,60%	2,46%	2,30%	1,69%	0,50%	13552,5
Des '16	3,02%	1,83%	0,20%	1,13%	2,59%	2,10%	2,07%	0,30%	13472,5

(halaman ini sengaja dikosongkan)

LAMPIRAN C

Lampiran C-1 Output MSE percobaan variable

1. ModelVar1

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	6,31E-05	5,48E-05	5,34E-05
2	logsig	learngdm	trainlm	100	1,50E-04	6,54E-05	2,88E-04
2	tansig	learngd	trainlm	100	2,92E-04	5,10E-05	5,26E-05
2	tansig	learngdm	trainlm	100	5,83E-05	4,92E-05	6,55E-05
2	purelin	learngd	trainlm	100	4,94E-05	4,97E-05	5,12E-05
2	purelin	learngdm	trainlm	100	5,09E-05	5,08E-05	5,10E-05
3	logsig	learngd	trainlm	100	5,08E-05	3,00E-04	4,96E-05
3	logsig	learngdm	trainlm	100	5,23E-05	7,00E-05	6,87E-05
3	tansig	learngd	trainlm	100	4,94E-05	7,73E-05	1,47E-04
3	tansig	learngdm	trainlm	100	5,11E-05	5,09E-05	5,09E-05
3	purelin	learngd	trainlm	100	1,71E-04	4,92E-05	5,25E-05
3	purelin	learngdm	trainlm	100	5,09E-05	5,07E-05	5,59E-05
4	logsig	learngd	trainlm	100	1,22E-04	1,50E-04	5,09E-05
4	logsig	learngdm	trainlm	100	1,99E-04	5,49E-05	1,52E-04
4	tansig	learngd	trainlm	100	5,74E-05	9,75E-04	2,81E-04
4	tansig	learngdm	trainlm	100	9,69E-05	5,20E-05	5,27E-05
4	purelin	learngd	trainlm	100	4,87E-05	5,12E-05	4,86E-05
4	purelin	learngdm	trainlm	100	4,94E-05	5,46E-05	5,19E-05
5	logsig	learngd	trainlm	100	6,94E-05	5,66E-05	5,83E-05
5	logsig	learngdm	trainlm	100	4,83E-05	4,92E-05	5,07E-04

node	active	learn	train	epoch	modelA	modelB	modelC
5	tansig	learngd	trainlm	100	6,26E-05	6,37E-05	6,10E-04
5	tansig	learngdm	trainlm	100	4,99E-05	7,07E-05	2,92E-04
5	purelin	learngd	trainlm	100	5,41E-05	5,07E-05	5,36E-05
5	purelin	learngdm	trainlm	100	5,17E-05	5,00E-05	5,24E-05
6	logsig	learngd	trainlm	100	6,63E-05	4,81E-05	5,49E-05
6	logsig	learngdm	trainlm	100	4,91E-05	6,48E-05	5,11E-04
6	tansig	learngd	trainlm	100	5,18E-05	1,73E-04	1,84E-04
6	tansig	learngdm	trainlm	100	7,09E-05	7,34E-05	5,23E-05
6	purelin	learngd	trainlm	100	4,97E-05	5,08E-05	5,17E-05
6	purelin	learngdm	trainlm	100	5,09E-05	4,98E-05	5,13E-05
7	logsig	learngd	trainlm	100	6,65E-05	1,30E-04	1,35E-04
7	logsig	learngdm	trainlm	100	2,36E-04	2,34E-04	7,45E-05
7	tansig	learngd	trainlm	100	1,19E-04	1,20E-04	2,26E-04
7	tansig	learngdm	trainlm	100	6,06E-05	5,78E-04	4,04E-04
7	purelin	learngd	trainlm	100	5,12E-05	4,93E-05	5,14E-05
7	purelin	learngdm	trainlm	100	4,98E-05	5,77E-05	4,94E-05
8	logsig	learngd	trainlm	100	1,25E-04	1,42E-04	8,50E-05
8	logsig	learngdm	trainlm	100	1,64E-04	4,93E-05	8,57E-05
8	tansig	learngd	trainlm	100	5,14E-05	7,75E-05	8,68E-05
8	tansig	learngdm	trainlm	100	5,14E-05	5,10E-05	2,09E-04
8	purelin	learngd	trainlm	100	5,06E-05	5,09E-05	5,48E-05
8	purelin	learngdm	trainlm	100	5,26E-05	4,92E-05	5,06E-05
9	logsig	learngd	trainlm	100	5,43E-05	7,21E-05	9,71E-05
9	logsig	learngdm	trainlm	100	9,68E-05	1,04E-04	1,04E-04
9	tansig	learngd	trainlm	100	6,55E-05	7,13E-05	6,33E-05

node	active	learn	train	epoch	modelA	modelB	modelC
9	tansig	learngdm	trainlm	100	5,25E-05	5,32E-05	6,12E-05
9	purelin	learngd	trainlm	100	4,90E-05	6,95E-05	5,85E-05
9	purelin	learngdm	trainlm	100	5,41E-05	5,03E-05	5,27E-05
10	logsig	learngd	trainlm	100	5,44E-05	2,93E-04	4,00E-04
10	logsig	learngdm	trainlm	100	8,54E-05	8,91E-05	9,64E-05
10	tansig	learngd	trainlm	100	5,98E-05	5,79E-05	5,77E-05
10	tansig	learngdm	trainlm	100	6,80E-05	7,30E-05	6,01E-05
10	purelin	learngd	trainlm	100	5,48E-05	5,20E-05	5,27E-05
10	purelin	learngdm	trainlm	100	4,99E-05	5,04E-05	4,91E-05
11	logsig	learngd	trainlm	100	6,03E-05	5,87E-05	5,74E-05
11	logsig	learngdm	trainlm	100	6,76E-05	5,91E-05	6,96E-05
11	tansig	learngd	trainlm	100	6,85E-05	7,49E-05	6,86E-05
11	tansig	learngdm	trainlm	100	7,23E-05	1,17E-04	5,45E-05
11	purelin	learngd	trainlm	100	5,03E-05	4,87E-05	4,94E-05
11	purelin	learngdm	trainlm	100	4,94E-05	5,04E-05	4,87E-05
12	logsig	learngd	trainlm	100	6,32E-05	3,32E-04	6,26E-05
12	logsig	learngdm	trainlm	100	6,56E-05	6,21E-05	7,56E-05
12	tansig	learngd	trainlm	100	7,70E-05	8,38E-05	7,17E-05
12	tansig	learngdm	trainlm	100	5,54E-05	5,81E-05	7,98E-05
12	purelin	learngd	trainlm	100	4,95E-05	4,99E-05	5,30E-05
12	purelin	learngdm	trainlm	100	5,02E-05	5,17E-05	5,04E-05
13	logsig	learngd	trainlm	100	6,49E-05	8,08E-05	6,95E-05
13	logsig	learngdm	trainlm	100	7,31E-05	1,06E-04	9,10E-05
13	tansig	learngd	trainlm	100	6,17E-05	6,26E-05	7,36E-05
13	tansig	learngdm	trainlm	100	7,56E-05	7,91E-05	7,33E-05

node	active	learn	train	epoch	modelA	modelB	modelC
13	purelin	learngd	trainlm	100	5,75E-05	4,87E-05	4,83E-05
13	purelin	learngdm	trainlm	100	5,18E-05	4,89E-05	4,96E-05
14	logsig	learngd	trainlm	100	6,87E-05	6,03E-05	1,15E-04
14	logsig	learngdm	trainlm	100	5,71E-05	8,32E-05	5,71E-05
14	tansig	learngd	trainlm	100	5,87E-05	6,00E-05	9,70E-05
14	tansig	learngdm	trainlm	100	1,09E-04	6,96E-05	6,62E-05
14	purelin	learngd	trainlm	100	5,05E-05	4,86E-05	5,07E-05
14	purelin	learngdm	trainlm	100	5,00E-05	4,90E-05	4,93E-05
15	logsig	learngd	trainlm	100	6,20E-05	6,30E-05	7,38E-05
15	logsig	learngdm	trainlm	100	4,94E-05	2,84E-04	5,88E-05
15	tansig	learngd	trainlm	100	8,45E-05	5,17E-05	5,99E-05
15	tansig	learngdm	trainlm	100	6,31E-05	5,44E-05	7,45E-05
15	purelin	learngd	trainlm	100	5,21E-05	4,92E-05	5,05E-05
15	purelin	learngdm	trainlm	100	4,95E-05	5,58E-05	5,23E-05
16	logsig	learngd	trainlm	100	5,65E-05	5,57E-05	7,24E-05
16	logsig	learngdm	trainlm	100	4,80E-05	5,92E-05	6,14E-05
16	tansig	learngd	trainlm	100	6,04E-05	5,84E-05	6,64E-05
16	tansig	learngdm	trainlm	100	5,41E-05	5,13E-05	1,03E-04
16	purelin	learngd	trainlm	100	4,96E-05	5,64E-05	5,22E-05
16	purelin	learngdm	trainlm	100	5,15E-05	1,13E-04	5,05E-05
17	logsig	learngd	trainlm	100	5,95E-05	6,95E-05	5,77E-05
17	logsig	learngdm	trainlm	100	9,12E-05	4,93E-05	8,72E-05
17	tansig	learngd	trainlm	100	6,74E-05	4,88E-05	6,32E-05
17	tansig	learngdm	trainlm	100	5,05E-05	5,13E-05	1,35E-04
17	purelin	learngd	trainlm	100	5,47E-05	5,52E-05	5,12E-05

node	active	learn	train	epoch	modelA	modelB	modelC
17	purelin	learngdm	trainlm	100	4,82E-05	4,94E-05	4,86E-05
18	logsig	learngd	trainlm	100	7,05E-05	6,10E-04	5,57E-05
18	logsig	learngdm	trainlm	100	5,10E-05	5,38E-05	1,50E-04
18	tansig	learngd	trainlm	100	5,82E-05	5,16E-05	5,32E-05
18	tansig	learngdm	trainlm	100	5,39E-05	6,20E-05	5,28E-05
18	purelin	learngd	trainlm	100	5,27E-05	5,24E-05	5,15E-05
18	purelin	learngdm	trainlm	100	5,03E-05	4,99E-05	6,32E-05
19	logsig	learngd	trainlm	100	1,62E-04	6,25E-05	6,24E-05
19	logsig	learngdm	trainlm	100	5,33E-05	5,89E-05	5,83E-05
19	tansig	learngd	trainlm	100	5,60E-05	6,28E-05	5,18E-05
19	tansig	learngdm	trainlm	100	1,47E-04	1,43E-04	6,03E-05
19	purelin	learngd	trainlm	100	5,03E-05	7,92E-05	5,22E-05
19	purelin	learngdm	trainlm	100	4,94E-05	5,16E-05	5,07E-05
20	logsig	learngd	trainlm	100	6,71E-05	1,62E-04	6,24E-05
20	logsig	learngdm	trainlm	100	6,82E-05	6,75E-05	7,12E-05
20	tansig	learngd	trainlm	100	6,97E-05	6,41E-05	5,77E-05
20	tansig	learngdm	trainlm	100	5,76E-05	6,96E-05	6,55E-05
20	purelin	learngd	trainlm	100	4,93E-05	4,95E-05	5,24E-05
20	purelin	learngdm	trainlm	100	5,02E-05	5,23E-05	2,04E-04
21	logsig	learngd	trainlm	100	6,94E-05	5,80E-05	1,53E-04
21	logsig	learngdm	trainlm	100	6,24E-05	7,18E-05	1,56E-04
21	tansig	learngd	trainlm	100	1,06E-04	1,12E-04	6,46E-05
21	tansig	learngdm	trainlm	100	5,49E-05	7,32E-05	6,74E-05
21	purelin	learngd	trainlm	100	5,03E-05	5,18E-05	5,03E-05
21	purelin	learngdm	trainlm	100	4,99E-05	5,10E-05	4,85E-05

2. ModelVar2

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	0,00186	0,00135	0,00100
2	logsig	learngdm	trainlm	100	0,00011	0,00027	0,00006
2	tansig	learngd	trainlm	100	0,00015	0,00010	0,00011
2	tansig	learngdm	trainlm	100	0,00042	0,00015	0,00012
2	purelin	learngd	trainlm	100	0,00009	0,00005	0,00006
2	purelin	learngdm	trainlm	100	0,00013	0,00011	0,00012
3	logsig	learngd	trainlm	100	0,00023	0,00182	0,00022
3	logsig	learngdm	trainlm	100	0,00147	0,01036	0,00033
3	tansig	learngd	trainlm	100	0,00258	0,00206	0,00157
3	tansig	learngdm	trainlm	100	0,00216	0,00391	0,00222
3	purelin	learngd	trainlm	100	0,00017	0,00006	0,00012
3	purelin	learngdm	trainlm	100	0,00011	0,00007	0,00011
4	logsig	learngd	trainlm	100	0,00674	0,00092	0,00177
4	logsig	learngdm	trainlm	100	0,00030	0,00062	0,00148
4	tansig	learngd	trainlm	100	0,00133	0,00010	0,00229
4	tansig	learngdm	trainlm	100	0,00005	0,00023	0,00143
4	purelin	learngd	trainlm	100	0,00009	0,00010	0,00007
4	purelin	learngdm	trainlm	100	0,00012	0,00015	0,00012
5	logsig	learngd	trainlm	100	0,00804	0,00080	0,00197
5	logsig	learngdm	trainlm	100	0,00029	0,00046	0,00115
5	tansig	learngd	trainlm	100	0,00058	0,00026	0,00138
5	tansig	learngdm	trainlm	100	0,00019	0,00007	0,00045
5	purelin	learngd	trainlm	100	0,00011	0,00011	0,00009
5	purelin	learngdm	trainlm	100	0,00014	0,00013	0,00009

node	active	learn	train	epoch	modelA	modelB	modelC
6	logsig	learngd	trainlm	100	0,00024	0,00049	0,00029
6	logsig	learngdm	trainlm	100	0,00231	0,00199	0,00254
6	tansig	learngd	trainlm	100	0,00503	0,00052	0,00007
6	tansig	learngdm	trainlm	100	0,00085	0,00014	0,00012
6	purelin	learngd	trainlm	100	0,00012	0,00010	0,00010
6	purelin	learngdm	trainlm	100	0,00008	0,00007	0,00005
7	logsig	learngd	trainlm	100	0,00044	0,00083	0,00304
7	logsig	learngdm	trainlm	100	0,00034	0,00084	0,00039
7	tansig	learngd	trainlm	100	0,02897	0,00492	0,00898
7	tansig	learngdm	trainlm	100	0,00302	0,00026	0,00129
7	purelin	learngd	trainlm	100	0,00010	0,00013	0,00009
7	purelin	learngdm	trainlm	100	0,00016	0,00014	0,00009
8	logsig	learngd	trainlm	100	0,00027	0,00018	0,00051
8	logsig	learngdm	trainlm	100	0,00253	0,00264	0,00328
8	tansig	learngd	trainlm	100	0,00461	0,00017	0,00406
8	tansig	learngdm	trainlm	100	0,00036	0,00060	0,00019
8	purelin	learngd	trainlm	100	0,00008	0,00012	0,00009
8	purelin	learngdm	trainlm	100	0,00014	0,00009	0,00012
9	logsig	learngd	trainlm	100	0,00119	0,00017	0,00061
9	logsig	learngdm	trainlm	100	0,00316	0,00196	0,00189
9	tansig	learngd	trainlm	100	0,00046	0,00093	0,00026
9	tansig	learngdm	trainlm	100	0,00015	0,00015	0,00131
9	purelin	learngd	trainlm	100	0,00036	0,00009	0,00016
9	purelin	learngdm	trainlm	100	0,00012	0,00007	0,00010
10	logsig	learngd	trainlm	100	0,00020	0,00092	0,00270

node	active	learn	train	epoch	modelA	modelB	modelC
10	logsig	learngdm	trainlm	100	0,00596	0,00064	0,00547
10	tansig	learngd	trainlm	100	0,00253	0,00274	0,00059
10	tansig	learngdm	trainlm	100	0,00916	0,00050	0,01050
10	purelin	learngd	trainlm	100	0,00010	0,00009	0,00009
10	purelin	learngdm	trainlm	100	0,00010	0,00015	0,00006
11	logsig	learngd	trainlm	100	0,00053	0,00048	0,00096
11	logsig	learngdm	trainlm	100	0,01425	0,01195	0,00070
11	tansig	learngd	trainlm	100	0,00007	0,00036	0,00099
11	tansig	learngdm	trainlm	100	0,00131	0,00153	0,00583
11	purelin	learngd	trainlm	100	0,00005	0,00007	0,00005
11	purelin	learngdm	trainlm	100	0,00007	0,00010	0,00013
12	logsig	learngd	trainlm	100	0,00006	0,00011	0,00022
12	logsig	learngdm	trainlm	100	0,00680	0,01229	0,00129
12	tansig	learngd	trainlm	100	0,00231	0,00119	0,00295
12	tansig	learngdm	trainlm	100	0,00224	0,00027	0,00170
12	purelin	learngd	trainlm	100	0,00012	0,00007	0,00007
13	logsig	learngd	trainlm	100	0,00354	0,00060	0,00051
13	logsig	learngdm	trainlm	100	0,00367	0,00306	0,00193
13	tansig	learngd	trainlm	100	0,00245	0,00503	0,00019
13	tansig	learngdm	trainlm	100	0,00022	0,00541	0,00020
13	purelin	learngd	trainlm	100	0,00015	0,00008	0,00009
13	purelin	learngdm	trainlm	100	0,00081	0,00017	0,00011
14	logsig	learngd	trainlm	100	0,00035	0,01377	0,00315
14	logsig	learngdm	trainlm	100	0,00400	0,00206	0,00030

node	active	learn	train	epoch	modelA	modelB	modelC
14	tansig	learngd	trainlm	100	0,00114	0,02551	0,00026
14	tansig	learngdm	trainlm	100	0,00017	0,00037	0,00110
14	purelin	learngd	trainlm	100	0,00011	0,00010	0,00017
14	purelin	learngdm	trainlm	100	0,00013	0,00012	0,00009
15	logsig	learngd	trainlm	100	0,00711	0,00060	0,00694
15	logsig	learngdm	trainlm	100	0,03520	0,00186	0,00658
15	tansig	learngd	trainlm	100	0,00020	0,00009	0,00015
15	tansig	learngdm	trainlm	100	0,00100	0,00073	0,00483
15	purelin	learngd	trainlm	100	0,00009	0,00011	0,00012
15	purelin	learngdm	trainlm	100	0,00010	0,00016	0,00018
16	logsig	learngd	trainlm	100	0,00019	0,00269	0,00161
16	logsig	learngdm	trainlm	100	0,02466	0,00100	0,00456
16	tansig	learngd	trainlm	100	0,01923	0,02366	0,00883
16	tansig	learngdm	trainlm	100	0,01428	0,00327	0,00130
16	purelin	learngd	trainlm	100	0,00007	0,00011	0,00011
16	purelin	learngdm	trainlm	100	0,00006	0,00015	0,00008
17	logsig	learngd	trainlm	100	0,01647	0,00051	0,00088
17	logsig	learngdm	trainlm	100	0,00042	0,00119	0,00009
17	tansig	learngd	trainlm	100	0,00398	0,00853	0,00618
17	tansig	learngdm	trainlm	100	0,01340	0,00127	0,01691
17	purelin	learngd	trainlm	100	0,00009	0,00014	0,00008
17	purelin	learngdm	trainlm	100	0,00010	0,00007	0,00011
18	logsig	learngd	trainlm	100	0,00027	0,00107	0,00151
18	logsig	learngdm	trainlm	100	0,00022	0,00015	0,00010
18	tansig	learngd	trainlm	100	0,00602	0,00352	0,00259

node	active	learn	train	epoch	modelA	modelB	modelC
18	tansig	learngdm	trainlm	100	0,00103	0,00356	0,00132
18	purelin	learngd	trainlm	100	0,00007	0,00007	0,00014
18	purelin	learngdm	trainlm	100	0,00009	0,00007	0,00013
19	logsig	learngd	trainlm	100	0,00062	0,00163	0,00060
19	logsig	learngdm	trainlm	100	0,00120	0,00183	0,00027
19	tansig	learngd	trainlm	100	0,01876	0,01808	0,01706
19	tansig	learngdm	trainlm	100	0,00036	0,00424	0,00051
19	purelin	learngd	trainlm	100	0,00009	0,00008	0,00009
19	purelin	learngdm	trainlm	100	0,00015	0,00006	0,00011
20	logsig	learngd	trainlm	100	0,04609	0,00303	0,02519
20	logsig	learngdm	trainlm	100	0,00099	0,00082	0,00083
20	tansig	learngd	trainlm	100	0,04091	0,01212	0,14054
20	tansig	learngdm	trainlm	100	0,00578	0,00549	0,01022
20	purelin	learngd	trainlm	100	0,00014	0,00006	0,00013
20	purelin	learngdm	trainlm	100	0,00010	0,00012	0,00015
21	logsig	learngd	trainlm	100	0,01366	0,01696	0,01965
21	logsig	learngdm	trainlm	100	0,00223	0,00164	0,00033
21	tansig	learngd	trainlm	100	0,00085	0,00125	0,00051
21	tansig	learngdm	trainlm	100	0,01983	0,02733	0,02647
21	purelin	learngd	trainlm	100	0,00009	0,00013	0,00008
21	purelin	learngdm	trainlm	100	0,00008	0,00013	0,00009

3. ModelVar3

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	0,01014	0,01980	0,03078
2	logsig	learngdm	trainlm	100	0,01941	0,06210	0,01336
2	tansig	learngd	trainlm	100	0,02927	0,03098	0,02144
2	tansig	learngdm	trainlm	100	0,01272	0,02041	0,01133
2	purelin	learngd	trainlm	100	0,07109	0,07679	0,06998
2	purelin	learngdm	trainlm	100	0,08218	0,05784	0,07347
3	logsig	learngd	trainlm	100	0,01041	0,02823	0,01065
3	logsig	learngdm	trainlm	100	0,02742	0,00888	0,01445
3	tansig	learngd	trainlm	100	0,00472	0,00329	0,00187
3	tansig	learngdm	trainlm	100	0,02136	0,01261	0,00859
3	purelin	learngd	trainlm	100	0,08442	0,06562	0,09414
3	purelin	learngdm	trainlm	100	0,09729	0,09081	0,06661
4	logsig	learngd	trainlm	100	0,02379	0,01714	0,03500
4	logsig	learngdm	trainlm	100	0,01638	0,01211	0,02223
4	tansig	learngd	trainlm	100	0,01301	0,01012	0,00944
4	tansig	learngdm	trainlm	100	0,00793	0,03372	0,03777
4	purelin	learngd	trainlm	100	0,07861	0,10773	0,07641
4	purelin	learngdm	trainlm	100	0,10150	0,08773	0,06549
5	logsig	learngd	trainlm	100	0,00798	0,01029	0,00611
5	logsig	learngdm	trainlm	100	0,01627	0,00413	0,03007
5	tansig	learngd	trainlm	100	0,03336	0,01718	0,04097
5	tansig	learngdm	trainlm	100	0,02694	0,02537	0,02224
5	purelin	learngd	trainlm	100	0,08013	0,08347	0,07207
5	purelin	learngdm	trainlm	100	0,07378	0,07021	0,07959

node	active	learn	train	epoch	modelA	modelB	modelC
6	logsig	learngd	trainlm	100	0,01910	0,02396	0,03278
6	logsig	learngdm	trainlm	100	0,00609	0,00401	0,00189
6	tansig	learngd	trainlm	100	0,01562	0,00714	0,01496
6	tansig	learngdm	trainlm	100	0,00680	0,00251	0,00714
6	purelin	learngd	trainlm	100	0,08675	0,09530	0,08340
6	purelin	learngdm	trainlm	100	0,08642	0,11534	0,06411
7	logsig	learngd	trainlm	100	0,00682	0,00693	0,01500
7	logsig	learngdm	trainlm	100	0,01407	0,00378	0,01423
7	tansig	learngd	trainlm	100	0,00444	0,00066	0,00394
7	tansig	learngdm	trainlm	100	0,00431	0,00615	0,00900
7	purelin	learngd	trainlm	100	0,04211	0,09178	0,08935
7	purelin	learngdm	trainlm	100	0,07693	0,07565	0,06901
8	logsig	learngd	trainlm	100	0,00902	0,00960	0,00595
8	logsig	learngdm	trainlm	100	0,03071	0,02836	0,01229
8	tansig	learngd	trainlm	100	0,02790	0,01478	0,00630
8	tansig	learngdm	trainlm	100	0,00935	0,02763	0,01706
8	purelin	learngd	trainlm	100	0,08928	0,07580	0,05280
8	purelin	learngdm	trainlm	100	0,08032	0,09015	0,08627
9	logsig	learngd	trainlm	100	0,01040	0,00966	0,01906
9	logsig	learngdm	trainlm	100	0,00394	0,00198	0,00110
9	tansig	learngd	trainlm	100	0,03209	0,02943	0,03629
9	tansig	learngdm	trainlm	100	0,02016	0,01269	0,00888
9	purelin	learngd	trainlm	100	0,07932	0,08609	0,09642
9	purelin	learngdm	trainlm	100	0,09216	0,07886	0,07135
10	logsig	learngd	trainlm	100	0,00569	0,00804	0,01055

node	active	learn	train	epoch	modelA	modelB	modelC
10	logsig	learngdm	trainlm	100	0,00415	0,00228	0,02314
10	tansig	learngd	trainlm	100	0,02069	0,03777	0,02927
10	tansig	learngdm	trainlm	100	0,00191	0,00215	0,00535
10	purelin	learngd	trainlm	100	0,09019	0,09453	0,06864
10	purelin	learngdm	trainlm	100	0,05763	0,04642	0,09717
11	logsig	learngd	trainlm	100	0,00214	0,00107	0,00060
11	logsig	learngdm	trainlm	100	0,00818	0,00395	0,00494
11	tansig	learngd	trainlm	100	0,01688	0,02127	0,00504
11	tansig	learngdm	trainlm	100	0,02630	0,01618	0,01983
11	purelin	learngd	trainlm	100	0,09542	0,06871	0,09259
11	purelin	learngdm	trainlm	100	0,08218	0,07128	0,06711
12	logsig	learngd	trainlm	100	0,04066	0,00327	0,01559
12	logsig	learngdm	trainlm	100	0,03308	0,02701	0,02743
12	tansig	learngd	trainlm	100	0,00765	0,01448	0,01743
12	tansig	learngdm	trainlm	100	0,01287	0,01940	0,02400
12	purelin	learngd	trainlm	100	0,06517	0,10269	0,06628
12	purelin	learngdm	trainlm	100	0,09096	0,10538	0,06284
13	logsig	learngd	trainlm	100	0,02284	0,01748	0,00874
13	logsig	learngdm	trainlm	100	0,00735	0,01739	0,00997
13	tansig	learngd	trainlm	100	0,00576	0,01241	0,01303
13	tansig	learngdm	trainlm	100	0,00907	0,00646	0,00161
13	purelin	learngd	trainlm	100	0,07256	0,06898	0,06465
13	purelin	learngdm	trainlm	100	0,08276	0,07736	0,09695
14	logsig	learngd	trainlm	100	0,02043	0,00905	0,00831
14	logsig	learngdm	trainlm	100	0,00555	0,00561	0,00497

node	active	learn	train	epoch	modelA	modelB	modelC
14	tansig	learngd	trainlm	100	0,01334	0,01860	0,01773
14	tansig	learngdm	trainlm	100	0,00529	0,00852	0,02240
14	purelin	learngd	trainlm	100	0,07047	0,03782	0,08575
14	purelin	learngdm	trainlm	100	0,09139	0,10776	0,08558
15	logsig	learngd	trainlm	100	0,00461	0,01467	0,00985
15	logsig	learngdm	trainlm	100	0,02009	0,00692	0,01609
15	tansig	learngd	trainlm	100	0,04396	0,00304	0,00226
15	tansig	learngdm	trainlm	100	0,00852	0,00778	0,00156
15	purelin	learngd	trainlm	100	0,07049	0,09262	0,07199
15	purelin	learngdm	trainlm	100	0,06529	0,08906	0,07350
16	logsig	learngd	trainlm	100	0,04737	0,01505	0,01492
16	logsig	learngdm	trainlm	100	0,00405	0,00279	0,00430
16	tansig	learngd	trainlm	100	0,00173	0,00174	0,00073
16	tansig	learngdm	trainlm	100	0,03144	0,00636	0,03077
16	purelin	learngd	trainlm	100	0,06124	0,08479	0,04763
16	purelin	learngdm	trainlm	100	0,10838	0,08099	0,06783
17	logsig	learngd	trainlm	100	0,00244	0,00391	0,00254
17	logsig	learngdm	trainlm	100	0,01707	0,00289	0,01112
17	tansig	learngd	trainlm	100	0,01688	0,00778	0,01071
17	tansig	learngdm	trainlm	100	0,00987	0,00219	0,00914
17	purelin	learngd	trainlm	100	0,07067	0,09275	0,08969
17	purelin	learngdm	trainlm	100	0,08456	0,08278	0,09332
18	logsig	learngd	trainlm	100	0,00760	0,00371	0,00236
18	logsig	learngdm	trainlm	100	0,00595	0,00861	0,01088
18	tansig	learngd	trainlm	100	0,00316	0,00256	0,00159

node	active	learn	train	epoch	modelA	modelB	modelC
18	tansig	learngdm	trainlm	100	0,00225	0,00647	0,02841
18	purelin	learngd	trainlm	100	0,06564	0,07612	0,09962
18	purelin	learngdm	trainlm	100	0,07873	0,08240	0,07050
19	logsig	learngd	trainlm	100	0,03248	0,03182	0,02162
19	logsig	learngdm	trainlm	100	0,01696	0,01424	0,00705
19	tansig	learngd	trainlm	100	0,00974	0,00727	0,00703
19	tansig	learngdm	trainlm	100	0,01977	0,00896	0,01740
19	purelin	learngd	trainlm	100	0,07790	0,10245	0,08468
19	purelin	learngdm	trainlm	100	0,02539	0,05410	0,09036
20	logsig	learngd	trainlm	100	0,00306	0,00663	0,00811
20	logsig	learngdm	trainlm	100	0,00256	0,00289	0,00286
20	tansig	learngd	trainlm	100	0,00546	0,00837	0,00416
20	tansig	learngdm	trainlm	100	0,01153	0,00571	0,01438
20	purelin	learngd	trainlm	100	0,10225	0,07300	0,08474
20	purelin	learngdm	trainlm	100	0,09070	0,08172	0,07674
21	logsig	learngd	trainlm	100	0,01103	0,02657	0,02404
21	logsig	learngdm	trainlm	100	0,01287	0,01764	0,00947
21	tansig	learngd	trainlm	100	0,01818	0,00513	0,01242
21	tansig	learngdm	trainlm	100	0,00292	0,01541	0,00217
21	purelin	learngd	trainlm	100	0,06760	0,08973	0,08777
21	purelin	learngdm	trainlm	100	0,08675	0,08112	0,07193

4. ModelVar4

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	0,00015	0,00021	0,00008
2	logsig	learngdm	trainlm	100	0,00188	0,00041	0,00030
2	tansig	learngd	trainlm	100	0,00007	0,00070	0,00147
2	tansig	learngdm	trainlm	100	0,00046	0,00054	0,00028
2	purelin	learngd	trainlm	100	0,00009	0,00012	0,00006
2	purelin	learngdm	trainlm	100	0,00009	0,00009	0,00012
3	logsig	learngd	trainlm	100	0,00172	0,00010	0,00458
3	logsig	learngdm	trainlm	100	0,00025	0,00218	0,00594
3	tansig	learngd	trainlm	100	0,00276	0,00053	0,00059
3	tansig	learngdm	trainlm	100	0,00890	0,00138	0,00044
3	purelin	learngd	trainlm	100	0,00010	0,00011	0,00009
3	purelin	learngdm	trainlm	100	0,00015	0,00014	0,00015
4	logsig	learngd	trainlm	100	0,00029	0,00087	0,00033
4	logsig	learngdm	trainlm	100	0,00028	0,00108	0,00025
4	tansig	learngd	trainlm	100	0,00533	0,00445	0,00461
4	tansig	learngdm	trainlm	100	0,00124	0,00047	0,00091
4	purelin	learngd	trainlm	100	0,00012	0,00008	0,00020
4	purelin	learngdm	trainlm	100	0,00013	0,00010	0,00011
5	logsig	learngd	trainlm	100	0,00044	0,00098	0,00009
5	logsig	learngdm	trainlm	100	0,00036	0,00008	0,00601
5	tansig	learngd	trainlm	100	0,00042	0,00712	0,00018
5	tansig	learngdm	trainlm	100	0,00010	0,00037	0,00011
5	purelin	learngd	trainlm	100	0,00023	0,00013	0,00010
5	purelin	learngdm	trainlm	100	0,00011	0,00008	0,00009

node	active	learn	train	epoch	modelA	modelB	modelC
6	logsig	learngd	trainlm	100	0,00011	0,00065	0,00155
6	logsig	learngdm	trainlm	100	0,00013	0,00041	0,00067
6	tansig	learngd	trainlm	100	0,00232	0,00331	0,00018
6	tansig	learngdm	trainlm	100	0,00016	0,00114	0,00349
6	purelin	learngd	trainlm	100	0,00015	0,00015	0,00007
6	purelin	learngdm	trainlm	100	0,00010	0,00008	0,00007
7	logsig	learngd	trainlm	100	0,00424	0,00333	0,00114
7	logsig	learngdm	trainlm	100	0,00218	0,00399	0,00160
7	tansig	learngd	trainlm	100	0,09291	0,02566	0,08394
7	tansig	learngdm	trainlm	100	0,00178	0,00158	0,00518
7	purelin	learngd	trainlm	100	0,00015	0,00012	0,00008
7	purelin	learngdm	trainlm	100	0,00026	0,00012	0,00015
8	logsig	learngd	trainlm	100	0,00238	0,01267	0,00893
8	logsig	learngdm	trainlm	100	0,01215	0,01488	0,00566
8	tansig	learngd	trainlm	100	0,00118	0,00365	0,00887
8	tansig	learngdm	trainlm	100	0,00020	0,00212	0,00193
8	purelin	learngd	trainlm	100	0,00012	0,00009	0,00010
8	purelin	learngdm	trainlm	100	0,00012	0,00011	0,00008
9	logsig	learngd	trainlm	100	0,00394	0,00772	0,00266
9	logsig	learngdm	trainlm	100	0,00259	0,00142	0,01250
9	tansig	learngd	trainlm	100	0,03078	0,00085	0,03213
9	tansig	learngdm	trainlm	100	0,00044	0,00064	0,00026
9	purelin	learngd	trainlm	100	0,00006	0,00012	0,00005
9	purelin	learngdm	trainlm	100	0,00007	0,00008	0,00012
10	logsig	learngd	trainlm	100	0,00158	0,00047	0,00050

node	active	learn	train	epoch	modelA	modelB	modelC
10	logsig	learngdm	trainlm	100	0,00169	0,00015	0,00879
10	tansig	learngd	trainlm	100	0,01773	0,00022	0,00084
10	tansig	learngdm	trainlm	100	0,00170	0,00681	0,00079
10	purelin	learngd	trainlm	100	0,00016	0,00009	0,00011
10	purelin	learngdm	trainlm	100	0,00015	0,00019	0,00011
11	logsig	learngd	trainlm	100	0,00018	0,00168	0,00184
11	logsig	learngdm	trainlm	100	0,00388	0,00924	0,00198
11	tansig	learngd	trainlm	100	0,01225	0,00432	0,00206
11	tansig	learngdm	trainlm	100	0,01531	0,01762	0,01774
11	purelin	learngd	trainlm	100	0,00009	0,00010	0,00013
11	purelin	learngdm	trainlm	100	0,00007	0,00013	0,00012
12	logsig	learngd	trainlm	100	0,00145	0,00062	0,00354
12	logsig	learngdm	trainlm	100	0,00149	0,00322	0,00542
12	tansig	learngd	trainlm	100	0,02237	0,01562	0,02836
12	tansig	learngdm	trainlm	100	0,00083	0,00017	0,00191
12	purelin	learngd	trainlm	100	0,00013	0,00006	0,00007
12	purelin	learngdm	trainlm	100	0,00011	0,00011	0,00014
13	logsig	learngd	trainlm	100	0,00391	0,00705	0,00310
13	logsig	learngdm	trainlm	100	0,02138	0,01176	0,00061
13	tansig	learngd	trainlm	100	0,00877	0,00513	0,00069
13	tansig	learngdm	trainlm	100	0,00152	0,00098	0,00139
13	purelin	learngd	trainlm	100	0,00012	0,00015	0,00011
13	purelin	learngdm	trainlm	100	0,00008	0,00007	0,00008
14	logsig	learngd	trainlm	100	0,01729	0,01122	0,00114
14	logsig	learngdm	trainlm	100	0,00486	0,00096	0,01019

node	active	learn	train	epoch	modelA	modelB	modelC
14	tansig	learngd	trainlm	100	0,00306	0,00023	0,00278
14	tansig	learngdm	trainlm	100	0,00994	0,02271	0,01444
14	purelin	learngd	trainlm	100	0,00014	0,00009	0,00070
14	purelin	learngdm	trainlm	100	0,00005	0,00009	0,00008
15	logsig	learngd	trainlm	100	0,00673	0,02635	0,00171
15	logsig	learngdm	trainlm	100	0,00028	0,00103	0,00937
15	tansig	learngd	trainlm	100	0,00198	0,00887	0,02332
15	tansig	learngdm	trainlm	100	0,00461	0,00258	0,00330
15	purelin	learngd	trainlm	100	0,00014	0,00006	0,00009
15	purelin	learngdm	trainlm	100	0,00010	0,00006	0,00012
16	logsig	learngd	trainlm	100	0,00210	0,00116	0,00339
16	logsig	learngdm	trainlm	100	0,02453	0,00044	0,00074
16	tansig	learngd	trainlm	100	0,00194	0,00311	0,00364
16	tansig	learngdm	trainlm	100	0,03046	0,02831	0,01801
16	purelin	learngd	trainlm	100	0,00012	0,00018	0,00007
16	purelin	learngdm	trainlm	100	0,00019	0,00007	0,00030
17	logsig	learngd	trainlm	100	0,00115	0,00246	0,00077
17	logsig	learngdm	trainlm	100	0,00243	0,01633	0,01669
17	tansig	learngd	trainlm	100	0,00170	0,00600	0,02139
17	tansig	learngdm	trainlm	100	0,00089	0,00078	0,00220
17	purelin	learngd	trainlm	100	0,00018	0,00007	0,00012
17	purelin	learngdm	trainlm	100	0,00011	0,00017	0,00018
18	logsig	learngd	trainlm	100	0,01765	0,00304	0,00447
18	logsig	learngdm	trainlm	100	0,00030	0,00072	0,00027
18	tansig	learngd	trainlm	100	0,00216	0,01034	0,00374

node	active	learn	train	epoch	modelA	modelB	modelC
18	tansig	learngdm	trainlm	100	0,00698	0,01877	0,00686
18	purelin	learngd	trainlm	100	0,00010	0,00020	0,00019
18	purelin	learngdm	trainlm	100	0,00017	0,00011	0,00012
19	logsig	learngd	trainlm	100	0,00926	0,00486	0,00242
19	logsig	learngdm	trainlm	100	0,00058	0,00091	0,00437
19	tansig	learngd	trainlm	100	0,04286	0,04289	0,00766
19	tansig	learngdm	trainlm	100	0,01286	0,00393	0,02961
19	purelin	learngd	trainlm	100	0,00007	0,00010	0,00025
19	purelin	learngdm	trainlm	100	0,00011	0,00011	0,00017
20	logsig	learngd	trainlm	100	0,00622	0,00139	0,01168
20	logsig	learngdm	trainlm	100	0,00018	0,00102	0,00017
20	tansig	learngd	trainlm	100	0,00418	0,00630	0,00565
20	tansig	learngdm	trainlm	100	0,00469	0,00493	0,00495
20	purelin	learngd	trainlm	100	0,00010	0,00012	0,00014
20	purelin	learngdm	trainlm	100	0,00011	0,00014	0,00012
21	logsig	learngd	trainlm	100	0,00041	0,00054	0,00682
21	logsig	learngdm	trainlm	100	0,00059	0,01151	0,00046
21	tansig	learngd	trainlm	100	0,00145	0,00054	0,00134
21	tansig	learngdm	trainlm	100	0,00394	0,02037	0,01871
21	purelin	learngd	trainlm	100	0,00011	0,00006	0,00012
21	purelin	learngdm	trainlm	100	0,00011	0,00008	0,00013

Lampiran C-2 Output MSE model terbaik Uji Periode Input

1. Periode peramalan 1 bulan

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	0,00047	0,01147	0,01159
2	logsig	learngdm	trainlm	100	0,00162	0,00041	0,00229
2	logsig	learngd	trainbfg	100	0,00142	0,00091	0,00076
2	logsig	learngdm	trainbfg	100	0,00908	0,00406	0,00526
2	tansig	learngd	trainlm	100	0,00013	0,00026	0,00032
2	tansig	learngdm	trainlm	100	0,00009	0,00009	0,00055
2	tansig	learngd	trainbfg	100	0,00163	0,00029	0,00029
2	tansig	learngdm	trainbfg	100	0,00477	0,00049	0,00046
2	purelin	learngd	trainlm	100	0,00007	0,00009	0,00012
2	purelin	learngdm	trainlm	100	0,00008	0,00007	0,00012
2	purelin	learngd	trainbfg	100	0,00014	0,00024	0,00045
2	purelin	learngdm	trainbfg	100	0,00010	0,00023	0,00046
3	logsig	learngd	trainlm	100	0,00082	0,00166	0,00137
3	logsig	learngdm	trainlm	100	0,00009	0,00005	0,00009
3	logsig	learngd	trainbfg	100	0,00147	0,00049	0,00320
3	logsig	learngdm	trainbfg	100	0,00130	0,00104	0,00110
3	tansig	learngd	trainlm	100	0,01192	0,01622	0,00089
3	tansig	learngdm	trainlm	100	0,00224	0,00982	0,01137
3	tansig	learngd	trainbfg	100	0,00069	0,00071	0,00117
3	tansig	learngdm	trainbfg	100	0,00089	0,00046	0,01003
3	purelin	learngd	trainlm	100	0,00009	0,00011	0,00012
3	purelin	learngdm	trainlm	100	0,00010	0,00012	0,00007

node	active	learn	train	epoch	modelA	modelB	modelC
3	purelin	learngd	trainbfg	100	0,00011	0,00030	0,00114
3	purelin	learngdm	trainbfg	100	0,00035	0,00017	0,00040
4	logsig	learngd	trainlm	100	0,00011	0,00027	0,00079
4	logsig	learngdm	trainlm	100	0,00128	0,00034	0,00014
4	logsig	learngd	trainbfg	100	0,00043	0,00091	0,00030
4	logsig	learngdm	trainbfg	100	0,00208	0,00094	0,00254
4	tansig	learngd	trainlm	100	0,00033	0,00193	0,00010
4	tansig	learngdm	trainlm	100	0,00098	0,01175	0,00538
4	tansig	learngd	trainbfg	100	0,00681	0,02219	0,02731
4	tansig	learngdm	trainbfg	100	0,00062	0,00987	0,00103
4	purelin	learngd	trainlm	100	0,00009	0,00014	0,00009
4	purelin	learngdm	trainlm	100	0,00018	0,00008	0,00007
4	purelin	learngd	trainbfg	100	0,00108	0,00200	0,00009
4	purelin	learngdm	trainbfg	100	0,00039	0,00010	0,00071
5	logsig	learngd	trainlm	100	0,00009	0,00017	0,00012
5	logsig	learngdm	trainlm	100	0,00012	0,00006	0,00010
5	logsig	learngd	trainbfg	100	0,00037	0,00012	0,00034
5	logsig	learngdm	trainbfg	100	0,00346	0,00038	0,00055
5	tansig	learngd	trainlm	100	0,00010	0,00186	0,00011
5	tansig	learngdm	trainlm	100	0,00431	0,00352	0,00020
5	tansig	learngd	trainbfg	100	0,00073	0,00059	0,00232
5	tansig	learngdm	trainbfg	100	0,00159	0,00076	0,00286
5	purelin	learngd	trainlm	100	0,00011	0,00009	0,00009
5	purelin	learngdm	trainlm	100	0,00009	0,00010	0,00008
5	purelin	learngd	trainbfg	100	0,00159	0,00160	0,00017

node	active	learn	train	epoch	modelA	modelB	modelC
5	purelin	learngdm	trainbfg	100	0,00056	0,00013	0,00155
6	logsig	learngd	trainlm	100	0,00020	0,00332	0,00410
6	logsig	learngdm	trainlm	100	0,00022	0,00037	0,00097
6	logsig	learngd	trainbfg	100	0,00258	0,00036	0,00408
6	logsig	learngdm	trainbfg	100	0,00100	0,00134	0,00049
6	tansig	learngd	trainlm	100	0,00074	0,00191	0,00020
6	tansig	learngdm	trainlm	100	0,00441	0,00226	0,00021
6	tansig	learngd	trainbfg	100	0,00090	0,00829	0,00692
6	tansig	learngdm	trainbfg	100	0,00057	0,00080	0,00088
6	purelin	learngd	trainlm	100	0,00008	0,00007	0,00011
6	purelin	learngdm	trainlm	100	0,00008	0,00010	0,00009
6	purelin	learngd	trainbfg	100	0,00020	0,00017	0,00011
6	purelin	learngdm	trainbfg	100	0,00013	0,00054	0,00011
7	logsig	learngd	trainlm	100	0,00080	0,00247	0,00259
7	logsig	learngdm	trainlm	100	0,00637	0,00142	0,00069
7	logsig	learngd	trainbfg	100	0,00707	0,00130	0,00266
7	logsig	learngdm	trainbfg	100	0,00114	0,00062	0,00119
7	tansig	learngd	trainlm	100	0,00158	0,00202	0,00053
7	tansig	learngdm	trainlm	100	0,00229	0,00538	0,00320
7	tansig	learngd	trainbfg	100	0,00128	0,00140	0,00199
7	tansig	learngdm	trainbfg	100	0,00113	0,00099	0,00024
7	purelin	learngd	trainlm	100	0,00011	0,00007	0,00008
7	purelin	learngdm	trainlm	100	0,00011	0,00007	0,00007
7	purelin	learngd	trainbfg	100	0,00007	0,00009	0,00015
7	purelin	learngdm	trainbfg	100	0,00009	0,00009	0,00013

node	active	learn	train	epoch	modelA	modelB	modelC
8	logsig	learngd	trainlm	100	0,00122	0,00578	0,00376
8	logsig	learngdm	trainlm	100	0,00131	0,00219	0,00027
8	logsig	learngd	trainbfg	100	0,00059	0,00204	0,00234
8	logsig	learngdm	trainbfg	100	0,00538	0,00068	0,00093
8	tansig	learngd	trainlm	100	0,00044	0,00082	0,00039
8	tansig	learngdm	trainlm	100	0,00038	0,00195	0,00204
8	tansig	learngd	trainbfg	100	0,00584	0,06902	0,05698
8	tansig	learngdm	trainbfg	100	0,00681	0,01707	0,00733
8	purelin	learngd	trainlm	100	0,00009	0,00010	0,00007
8	purelin	learngdm	trainlm	100	0,00042	0,00032	0,00007
8	purelin	learngd	trainbfg	100	0,00019	0,00012	0,00059
8	purelin	learngdm	trainbfg	100	0,00051	0,00029	0,00029
9	logsig	learngd	trainlm	100	0,00223	0,00194	0,00165
9	logsig	learngdm	trainlm	100	0,00163	0,00745	0,00732
9	logsig	learngd	trainbfg	100	0,01073	0,01216	0,02537
9	logsig	learngdm	trainbfg	100	0,01014	0,02284	0,00876
9	tansig	learngd	trainlm	100	0,00033	0,00037	0,00136
9	tansig	learngdm	trainlm	100	0,00115	0,00110	0,00075
9	tansig	learngd	trainbfg	100	0,00586	0,00045	0,00161
9	tansig	learngdm	trainbfg	100	0,00088	0,00527	0,00255
9	purelin	learngd	trainlm	100	0,00009	0,00007	0,00006
9	purelin	learngdm	trainlm	100	0,00007	0,00007	0,00007
9	purelin	learngd	trainbfg	100	0,00089	0,00035	0,00035
9	purelin	learngdm	trainbfg	100	0,00053	0,00010	0,00011
10	logsig	learngd	trainlm	100	0,00066	0,00041	0,00057

node	active	learn	train	epoch	modelA	modelB	modelC
10	logsig	learngdm	trainlm	100	0,00069	0,00023	0,00037
10	logsig	learngd	trainbfg	100	0,00063	0,00073	0,00059
10	logsig	learngdm	trainbfg	100	0,01782	0,01451	0,00032
10	tansig	learngd	trainlm	100	0,00039	0,00201	0,00230
10	tansig	learngdm	trainlm	100	0,00140	0,00040	0,00334
10	tansig	learngd	trainbfg	100	0,00124	0,00200	0,00163
10	tansig	learngdm	trainbfg	100	0,00501	0,00100	0,00098
10	purelin	learngd	trainlm	100	0,00007	0,00010	0,00008
10	purelin	learngdm	trainlm	100	0,00009	0,00009	0,00009
10	purelin	learngd	trainbfg	100	0,00012	0,00008	0,00009
10	purelin	learngdm	trainbfg	100	0,00009	0,00016	0,00012
11	logsig	learngd	trainlm	100	0,00308	0,00934	0,00693
11	logsig	learngdm	trainlm	100	0,00560	0,00063	0,00498
11	logsig	learngd	trainbfg	100	0,00066	0,02022	0,00274
11	logsig	learngdm	trainbfg	100	0,00614	0,00673	0,00081
11	tansig	learngd	trainlm	100	0,00257	0,00104	0,00043
11	tansig	learngdm	trainlm	100	0,00013	0,00026	0,00065
11	tansig	learngd	trainbfg	100	0,02707	0,03190	0,03040
11	tansig	learngdm	trainbfg	100	0,01058	0,02862	0,01532
11	purelin	learngd	trainlm	100	0,00007	0,00012	0,00013
11	purelin	learngdm	trainlm	100	0,00011	0,00008	0,00008
11	purelin	learngd	trainbfg	100	0,00030	0,00007	0,00012
11	purelin	learngdm	trainbfg	100	0,00012	0,00012	0,00008
12	logsig	learngd	trainlm	100	0,00080	0,00112	0,00204
12	logsig	learngdm	trainlm	100	0,00007	0,00246	0,00408

node	active	learn	train	epoch	modelA	modelB	modelC
12	logsig	learngd	trainbfg	100	0,00023	0,00027	0,00051
12	logsig	learngdm	trainbfg	100	0,00120	0,00466	0,00150
12	tansig	learngd	trainlm	100	0,00682	0,00751	0,00227
12	tansig	learngdm	trainlm	100	0,00008	0,00056	0,00146
12	tansig	learngd	trainbfg	100	0,00078	0,00179	0,00189
12	tansig	learngdm	trainbfg	100	0,00082	0,00405	0,00455
12	purelin	learngd	trainlm	100	0,00013	0,00011	0,00007
12	purelin	learngdm	trainlm	100	0,00016	0,00009	0,00014
12	purelin	learngd	trainbfg	100	0,00009	0,00009	0,00010
12	purelin	learngdm	trainbfg	100	0,00016	0,00010	0,00011
13	logsig	learngd	trainlm	100	0,00102	0,00140	0,00115
13	logsig	learngdm	trainlm	100	0,00078	0,00567	0,00057
13	logsig	learngd	trainbfg	100	0,00736	0,01264	0,00883
13	logsig	learngdm	trainbfg	100	0,00163	0,00630	0,00101
13	tansig	learngd	trainlm	100	0,00654	0,00657	0,00972
13	tansig	learngdm	trainlm	100	0,00349	0,00359	0,00024
13	tansig	learngd	trainbfg	100	0,00415	0,01059	0,01016
13	tansig	learngdm	trainbfg	100	0,00562	0,00246	0,00993
13	purelin	learngd	trainlm	100	0,00009	0,00007	0,00007
13	purelin	learngdm	trainlm	100	0,00008	0,00010	0,00008
13	purelin	learngd	trainbfg	100	0,00007	0,00019	0,00016
13	purelin	learngdm	trainbfg	100	0,00036	0,00029	0,00041
14	logsig	learngd	trainlm	100	0,00632	0,00496	0,00519
14	logsig	learngdm	trainlm	100	0,00092	0,00014	0,00014
14	logsig	learngd	trainbfg	100	0,00049	0,00030	0,00044

node	active	learn	train	epoch	modelA	modelB	modelC
14	logsig	learngdm	trainbfg	100	0,00072	0,00156	0,00057
14	tansig	learngd	trainlm	100	0,00024	0,00132	0,00112
14	tansig	learngdm	trainlm	100	0,01513	0,00424	0,00140
14	tansig	learngd	trainbfg	100	0,00062	0,00239	0,00125
14	tansig	learngdm	trainbfg	100	0,01297	0,01373	0,00422
14	purelin	learngd	trainlm	100	0,00009	0,00008	0,00008
14	purelin	learngdm	trainlm	100	0,00010	0,00012	0,00013
14	purelin	learngd	trainbfg	100	0,00019	0,00017	0,00015
14	purelin	learngdm	trainbfg	100	0,00009	0,00021	0,00012
15	logsig	learngd	trainlm	100	0,00028	0,00025	0,00054
15	logsig	learngdm	trainlm	100	0,00166	0,00099	0,00030
15	logsig	learngd	trainbfg	100	0,00215	0,00399	0,00521
15	logsig	learngdm	trainbfg	100	0,01105	0,00871	0,00541
15	tansig	learngd	trainlm	100	0,00029	0,00041	0,00052
15	tansig	learngdm	trainlm	100	0,00213	0,00023	0,00238
15	tansig	learngd	trainbfg	100	0,01001	0,01734	0,02057
15	tansig	learngdm	trainbfg	100	0,00107	0,00122	0,00773
15	purelin	learngd	trainlm	100	0,00014	0,00014	0,00008
15	purelin	learngdm	trainlm	100	0,00006	0,00014	0,00026
15	purelin	learngd	trainbfg	100	0,00007	0,00025	0,00032
15	purelin	learngdm	trainbfg	100	0,00217	0,00012	0,00010
16	logsig	learngd	trainlm	100	0,00157	0,01265	0,00085
16	logsig	learngdm	trainlm	100	0,00009	0,00058	0,00924
16	logsig	learngd	trainbfg	100	0,00108	0,00172	0,00517
16	logsig	learngdm	trainbfg	100	0,01173	0,00046	0,00338

node	active	learn	train	epoch	modelA	modelB	modelC
16	tansig	learngd	trainlm	100	0,00061	0,00089	0,00075
16	tansig	learngdm	trainlm	100	0,00235	0,00914	0,01376
16	tansig	learngd	trainbfg	100	0,02262	0,00944	0,00559
16	tansig	learngdm	trainbfg	100	0,00605	0,00495	0,00058
16	purelin	learngd	trainlm	100	0,00009	0,00011	0,00008
16	purelin	learngdm	trainlm	100	0,00010	0,00009	0,00007
16	purelin	learngd	trainbfg	100	0,00009	0,00012	0,00020
16	purelin	learngdm	trainbfg	100	0,00010	0,00026	0,00035
17	logsig	learngd	trainlm	100	0,00310	0,00905	0,00149
17	logsig	learngdm	trainlm	100	0,00239	0,00258	0,00153
17	logsig	learngd	trainbfg	100	0,01775	0,00500	0,02132
17	logsig	learngdm	trainbfg	100	0,00025	0,00087	0,00133
17	tansig	learngd	trainlm	100	0,00187	0,00107	0,00052
17	tansig	learngdm	trainlm	100	0,00039	0,00355	0,00160
17	tansig	learngd	trainbfg	100	0,02052	0,01878	0,00954
17	tansig	learngdm	trainbfg	100	0,00036	0,00302	0,00408
17	purelin	learngd	trainlm	100	0,00008	0,00008	0,00009
17	purelin	learngdm	trainlm	100	0,00009	0,00007	0,00008
17	purelin	learngd	trainbfg	100	0,00007	0,00008	0,00011
17	purelin	learngdm	trainbfg	100	0,00017	0,00011	0,00016
18	logsig	learngd	trainlm	100	0,00100	0,00292	0,00396
18	logsig	learngdm	trainlm	100	0,00335	0,00033	0,00047
18	logsig	learngd	trainbfg	100	0,01805	0,00192	0,00032
18	logsig	learngdm	trainbfg	100	0,00592	0,00657	0,00662
18	tansig	learngd	trainlm	100	0,00539	0,00020	0,00143

node	active	learn	train	epoch	modelA	modelB	modelC
18	tansig	learngdm	trainlm	100	0,00072	0,00085	0,01120
18	tansig	learngd	trainbfg	100	0,00103	0,00334	0,00609
18	tansig	learngdm	trainbfg	100	0,01891	0,01874	0,02779
18	purelin	learngd	trainlm	100	0,00008	0,00009	0,00009
18	purelin	learngdm	trainlm	100	0,00008	0,00008	0,00010
18	purelin	learngd	trainbfg	100	0,00017	0,00172	0,00042
18	purelin	learngdm	trainbfg	100	0,00016	0,00015	0,00008
19	logsig	learngd	trainlm	100	0,00069	0,00014	0,00119
19	logsig	learngdm	trainlm	100	0,00073	0,00315	0,00064
19	logsig	learngd	trainbfg	100	0,01022	0,01463	0,01471
19	logsig	learngdm	trainbfg	100	0,00009	0,00154	0,00399
19	tansig	learngd	trainlm	100	0,00094	0,00175	0,00222
19	tansig	learngdm	trainlm	100	0,00041	0,00144	0,00025
19	tansig	learngd	trainbfg	100	0,00221	0,00053	0,00012
19	tansig	learngdm	trainbfg	100	0,00033	0,00034	0,00084
19	purelin	learngd	trainlm	100	0,00007	0,00008	0,00010
19	purelin	learngdm	trainlm	100	0,00009	0,00008	0,00017
19	purelin	learngd	trainbfg	100	0,00011	0,00009	0,00012
19	purelin	learngdm	trainbfg	100	0,00082	0,00065	0,00010
20	logsig	learngd	trainlm	100	0,00067	0,00051	0,00158
20	logsig	learngdm	trainlm	100	0,00487	0,00201	0,00422
20	logsig	learngd	trainbfg	100	0,00579	0,00196	0,00117
20	logsig	learngdm	trainbfg	100	0,00861	0,00982	0,01445
20	tansig	learngd	trainlm	100	0,00093	0,00165	0,00362
20	tansig	learngdm	trainlm	100	0,00147	0,00285	0,00205

node	active	learn	train	epoch	modelA	modelB	modelC
20	tansig	learngd	trainbfg	100	0,01759	0,01525	0,02421
20	tansig	learngdm	trainbfg	100	0,01978	0,00319	0,00358
20	purelin	learngd	trainlm	100	0,00008	0,00007	0,00007
20	purelin	learngdm	trainlm	100	0,00007	0,00008	0,00008
20	purelin	learngd	trainbfg	100	0,00009	0,00008	0,00007
20	purelin	learngdm	trainbfg	100	0,00013	0,00020	0,00014
21	logsig	learngd	trainlm	100	0,01404	0,02390	0,01915
21	logsig	learngdm	trainlm	100	0,00032	0,00177	0,00150
21	logsig	learngd	trainbfg	100	0,00177	0,00397	0,00216
21	logsig	learngdm	trainbfg	100	0,00131	0,00074	0,00041
21	tansig	learngd	trainlm	100	0,00948	0,00429	0,00726
21	tansig	learngdm	trainlm	100	0,00273	0,01677	0,00507
21	tansig	learngd	trainbfg	100	0,00139	0,00040	0,00156
21	tansig	learngdm	trainbfg	100	0,01973	0,01939	0,01742
21	purelin	learngd	trainlm	100	0,00008	0,00009	0,00010
21	purelin	learngdm	trainlm	100	0,00009	0,00009	0,00011
21	purelin	learngd	trainbfg	100	0,00016	0,00016	0,00009
21	purelin	learngdm	trainbfg	100	0,00017	0,00011	0,00024

2. Periode peramalan 3 bulan

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	0,00987	0,00035	0,00068
2	logsig	learngdm	trainlm	100	0,00013	0,01262	0,00028
2	logsig	learngd	trainbfg	100	0,00129	0,00130	0,00376
2	logsig	learngdm	trainbfg	100	0,00077	0,00240	0,00100

node	active	learn	train	epoch	modelA	modelB	modelC
2	tansig	learngd	trainlm	100	0,00552	0,03704	0,01609
2	tansig	learngdm	trainlm	100	0,00335	0,00148	0,00154
2	tansig	learngd	trainbfg	100	0,00030	0,00016	0,00386
2	tansig	learngdm	trainbfg	100	0,00073	0,00186	0,00305
2	purelin	learngd	trainlm	100	0,00026	0,00024	0,00041
2	purelin	learngdm	trainlm	100	0,00031	0,00034	0,00040
2	purelin	learngd	trainbfg	100	0,00019	0,00145	0,00021
2	purelin	learngdm	trainbfg	100	0,00031	0,00027	0,00031
3	logsig	learngd	trainlm	100	0,00205	0,00839	0,00590
3	logsig	learngdm	trainlm	100	0,00108	0,02313	0,02852
3	logsig	learngd	trainbfg	100	0,00221	0,00060	0,00181
3	logsig	learngdm	trainbfg	100	0,00104	0,00097	0,00056
3	tansig	learngd	trainlm	100	0,00156	0,00714	0,01293
3	tansig	learngdm	trainlm	100	0,00623	0,00159	0,00123
3	tansig	learngd	trainbfg	100	0,00178	0,00076	0,00051
3	tansig	learngdm	trainbfg	100	0,00846	0,01010	0,00844
3	purelin	learngd	trainlm	100	0,00019	0,00018	0,00026
3	purelin	learngdm	trainlm	100	0,00039	0,00025	0,00049
3	purelin	learngd	trainbfg	100	0,00097	0,00287	0,00023
3	purelin	learngdm	trainbfg	100	0,00029	0,00015	0,00021
4	logsig	learngd	trainlm	100	0,00028	0,00017	0,00020
4	logsig	learngdm	trainlm	100	0,00135	0,00442	0,00306
4	logsig	learngd	trainbfg	100	0,00711	0,00614	0,00131
4	logsig	learngdm	trainbfg	100	0,00088	0,00121	0,00080
4	tansig	learngd	trainlm	100	0,00020	0,00034	0,00012

node	active	learn	train	epoch	modelA	modelB	modelC
4	tansig	learngdm	trainlm	100	0,00623	0,00286	0,00387
4	tansig	learngd	trainbfg	100	0,00282	0,00304	0,00562
4	tansig	learngdm	trainbfg	100	0,00066	0,00034	0,00048
4	purelin	learngd	trainlm	100	0,00026	0,00015	0,00026
4	purelin	learngdm	trainlm	100	0,00036	0,00052	0,00017
4	purelin	learngd	trainbfg	100	0,00072	0,00028	0,00029
4	purelin	learngdm	trainbfg	100	0,00019	0,00061	0,00036
5	logsig	learngd	trainlm	100	0,00202	0,00202	0,00039
5	logsig	learngdm	trainlm	100	0,00113	0,00072	0,00018
5	logsig	learngd	trainbfg	100	0,01175	0,00309	0,00335
5	logsig	learngdm	trainbfg	100	0,00078	0,00052	0,00326
5	tansig	learngd	trainlm	100	0,07469	0,00444	0,00583
5	tansig	learngdm	trainlm	100	0,00029	0,00038	0,09105
5	tansig	learngd	trainbfg	100	0,01728	0,00805	0,00447
5	tansig	learngdm	trainbfg	100	0,00292	0,00272	0,00324
5	purelin	learngd	trainlm	100	0,00020	0,00036	0,00013
5	purelin	learngdm	trainlm	100	0,00044	0,00036	0,00021
5	purelin	learngd	trainbfg	100	0,00030	0,00032	0,00029
5	purelin	learngdm	trainbfg	100	0,00018	0,00106	0,00030
6	logsig	learngd	trainlm	100	0,00428	0,00730	0,00191
6	logsig	learngdm	trainlm	100	0,00091	0,03464	0,00060
6	logsig	learngd	trainbfg	100	0,00106	0,00090	0,00060
6	logsig	learngdm	trainbfg	100	0,00309	0,01086	0,00289
6	tansig	learngd	trainlm	100	0,01113	0,00159	0,00450
6	tansig	learngdm	trainlm	100	0,00239	0,00309	0,00029

node	active	learn	train	epoch	modelA	modelB	modelC
6	tansig	learngd	trainbfg	100	0,00034	0,00054	0,00058
6	tansig	learngdm	trainbfg	100	0,00103	0,00096	0,00176
6	purelin	learngd	trainlm	100	0,00021	0,00024	0,00032
6	purelin	learngdm	trainlm	100	0,00028	0,00036	0,00012
6	purelin	learngd	trainbfg	100	0,00031	0,00106	0,00080
6	purelin	learngdm	trainbfg	100	0,00020	0,00074	0,00029
7	logsig	learngd	trainlm	100	0,00421	0,00048	0,00477
7	logsig	learngdm	trainlm	100	0,01134	0,00176	0,00041
7	logsig	learngd	trainbfg	100	0,00053	0,00208	0,00205
7	logsig	learngdm	trainbfg	100	0,00971	0,00916	0,02514
7	tansig	learngd	trainlm	100	0,07703	0,03030	0,00094
7	tansig	learngdm	trainlm	100	0,00240	0,00061	0,00037
7	tansig	learngd	trainbfg	100	0,02025	0,00948	0,01054
7	tansig	learngdm	trainbfg	100	0,01312	0,00732	0,00903
7	purelin	learngd	trainlm	100	0,00023	0,00030	0,00084
7	purelin	learngdm	trainlm	100	0,00024	0,00037	0,00052
7	purelin	learngd	trainbfg	100	0,00165	0,00115	0,00056
7	purelin	learngdm	trainbfg	100	0,00021	0,00027	0,00040
8	logsig	learngd	trainlm	100	0,00116	0,00302	0,00228
8	logsig	learngdm	trainlm	100	0,00913	0,00301	0,00462
8	logsig	learngd	trainbfg	100	0,00328	0,00982	0,00754
8	logsig	learngdm	trainbfg	100	0,00145	0,00067	0,00195
8	tansig	learngd	trainlm	100	0,00986	0,00040	0,00186
8	tansig	learngdm	trainlm	100	0,02962	0,07773	0,08387
8	tansig	learngd	trainbfg	100	0,00514	0,00094	0,00300

node	active	learn	train	epoch	modelA	modelB	modelC
8	tansig	learngdm	trainbfg	100	0,00916	0,00875	0,00663
8	purelin	learngd	trainlm	100	0,00015	0,00060	0,00029
8	purelin	learngdm	trainlm	100	0,00028	0,00021	0,00021
8	purelin	learngd	trainbfg	100	0,00015	0,00030	0,00032
8	purelin	learngdm	trainbfg	100	0,00040	0,00032	0,00076
9	logsig	learngd	trainlm	100	0,01011	0,00233	0,01038
9	logsig	learngdm	trainlm	100	0,00533	0,00080	0,00353
9	logsig	learngd	trainbfg	100	0,01565	0,00326	0,00672
9	logsig	learngdm	trainbfg	100	0,00379	0,00368	0,00360
9	tansig	learngd	trainlm	100	0,00267	0,01476	0,00614
9	tansig	learngdm	trainlm	100	0,00245	0,00332	0,04144
9	tansig	learngd	trainbfg	100	0,00848	0,02518	0,02126
9	tansig	learngdm	trainbfg	100	0,00867	0,00266	0,00427
9	purelin	learngd	trainlm	100	0,00013	0,00023	0,00016
9	purelin	learngdm	trainlm	100	0,00032	0,00048	0,00038
9	purelin	learngd	trainbfg	100	0,00043	0,00038	0,00034
9	purelin	learngdm	trainbfg	100	0,00052	0,00020	0,00041
10	logsig	learngd	trainlm	100	0,01523	0,01450	0,00140
10	logsig	learngdm	trainlm	100	0,01424	0,01084	0,00628
10	logsig	learngd	trainbfg	100	0,01615	0,01690	0,02692
10	logsig	learngdm	trainbfg	100	0,00066	0,00352	0,00655
10	tansig	learngd	trainlm	100	0,02668	0,03515	0,06102
10	tansig	learngdm	trainlm	100	0,00161	0,00054	0,00294
10	tansig	learngd	trainbfg	100	0,00190	0,02447	0,00418
10	tansig	learngdm	trainbfg	100	0,00983	0,01007	0,01256

node	active	learn	train	epoch	modelA	modelB	modelC
10	purelin	learngd	trainlm	100	0,00027	0,00020	0,00054
10	purelin	learngdm	trainlm	100	0,00023	0,00036	0,00024
10	purelin	learngd	trainbfg	100	0,00043	0,00038	0,00053
10	purelin	learngdm	trainbfg	100	0,00049	0,00033	0,00053
11	logsig	learngd	trainlm	100	0,05259	0,00172	0,00086
11	logsig	learngdm	trainlm	100	0,00594	0,00294	0,00805
11	logsig	learngd	trainbfg	100	0,01347	0,01377	0,00598
11	logsig	learngdm	trainbfg	100	0,01752	0,02215	0,02274
11	tansig	learngd	trainlm	100	0,00457	0,00196	0,00129
11	tansig	learngdm	trainlm	100	0,01553	0,00352	0,00268
11	tansig	learngd	trainbfg	100	0,03695	0,01884	0,01367
11	tansig	learngdm	trainbfg	100	0,00461	0,00081	0,00494
11	purelin	learngd	trainlm	100	0,00034	0,00017	0,00030
11	purelin	learngdm	trainlm	100	0,00040	0,00029	0,00041
11	purelin	learngd	trainbfg	100	0,00030	0,00016	0,00026
11	purelin	learngdm	trainbfg	100	0,00043	0,00024	0,00039
12	logsig	learngd	trainlm	100	0,03106	0,00962	0,00599
12	logsig	learngdm	trainlm	100	0,03663	0,02041	0,00081
12	logsig	learngd	trainbfg	100	0,00102	0,00126	0,00111
12	logsig	learngdm	trainbfg	100	0,00706	0,00707	0,00933
12	tansig	learngd	trainlm	100	0,00393	0,00119	0,00523
12	tansig	learngdm	trainlm	100	0,00507	0,00978	0,01420
12	tansig	learngd	trainbfg	100	0,00849	0,00429	0,00413
12	tansig	learngdm	trainbfg	100	0,01410	0,01519	0,00610
12	purelin	learngd	trainlm	100	0,00033	0,00038	0,00027

node	active	learn	train	epoch	modelA	modelB	modelC
12	purelin	learngdm	trainlm	100	0,00016	0,00054	0,00040
12	purelin	learngd	trainbfg	100	0,00056	0,00044	0,00374
12	purelin	learngdm	trainbfg	100	0,00039	0,00150	0,00033
13	logsig	learngd	trainlm	100	0,00560	0,01914	0,00068
13	logsig	learngdm	trainlm	100	0,03567	0,01581	0,08561
13	logsig	learngd	trainbfg	100	0,00182	0,00146	0,00113
13	logsig	learngdm	trainbfg	100	0,00287	0,00731	0,00222
13	tansig	learngd	trainlm	100	0,01521	0,00431	0,02378
13	tansig	learngdm	trainlm	100	0,00055	0,00297	0,00394
13	tansig	learngd	trainbfg	100	0,00446	0,00527	0,00147
13	tansig	learngdm	trainbfg	100	0,00249	0,00087	0,00703
13	purelin	learngd	trainlm	100	0,00016	0,00016	0,00032
13	purelin	learngdm	trainlm	100	0,00017	0,00028	0,00030
13	purelin	learngd	trainbfg	100	0,00015	0,00032	0,00086
13	purelin	learngdm	trainbfg	100	0,00097	0,00042	0,00020
14	logsig	learngd	trainlm	100	0,00570	0,00572	0,00375
14	logsig	learngdm	trainlm	100	0,00363	0,01551	0,02029
14	logsig	learngd	trainbfg	100	0,00525	0,01046	0,01530
14	logsig	learngdm	trainbfg	100	0,00565	0,01074	0,00797
14	tansig	learngd	trainlm	100	0,00934	0,03234	0,01841
14	tansig	learngdm	trainlm	100	0,00461	0,00400	0,00706
14	tansig	learngd	trainbfg	100	0,00261	0,00410	0,00333
14	tansig	learngdm	trainbfg	100	0,01440	0,01050	0,00323
14	purelin	learngd	trainlm	100	0,00031	0,00035	0,00022
14	purelin	learngdm	trainlm	100	0,00018	0,00019	0,00022

node	active	learn	train	epoch	modelA	modelB	modelC
14	purelin	learngd	trainbfg	100	0,00039	0,00029	0,00035
14	purelin	learngdm	trainbfg	100	0,00025	0,00024	0,00021
15	logsig	learngd	trainlm	100	0,00054	0,00081	0,00021
15	logsig	learngdm	trainlm	100	0,01349	0,00365	0,00139
15	logsig	learngd	trainbfg	100	0,01009	0,01323	0,02895
15	logsig	learngdm	trainbfg	100	0,00190	0,00395	0,03025
15	tansig	learngd	trainlm	100	0,01763	0,01041	0,02167
15	tansig	learngdm	trainlm	100	0,00333	0,00353	0,01573
15	tansig	learngd	trainbfg	100	0,01335	0,01125	0,00510
15	tansig	learngdm	trainbfg	100	0,02878	0,01739	0,02074
15	purelin	learngd	trainlm	100	0,00024	0,00027	0,00023
15	purelin	learngdm	trainlm	100	0,00017	0,00019	0,00028
15	purelin	learngd	trainbfg	100	0,00018	0,00033	0,00029
15	purelin	learngdm	trainbfg	100	0,00154	0,00046	0,00062
16	logsig	learngd	trainlm	100	0,00840	0,00757	0,03237
16	logsig	learngdm	trainlm	100	0,00174	0,00499	0,00390
16	logsig	learngd	trainbfg	100	0,00740	0,00483	0,01749
16	logsig	learngdm	trainbfg	100	0,01437	0,01257	0,01105
16	tansig	learngd	trainlm	100	0,00541	0,00236	0,00510
16	tansig	learngdm	trainlm	100	0,01466	0,01105	0,02177
16	tansig	learngd	trainbfg	100	0,01400	0,01645	0,01688
16	tansig	learngdm	trainbfg	100	0,02150	0,01535	0,02551
16	purelin	learngd	trainlm	100	0,00017	0,00031	0,00021
16	purelin	learngdm	trainlm	100	0,00040	0,00053	0,00023
16	purelin	learngd	trainbfg	100	0,00042	0,00067	0,00053

node	active	learn	train	epoch	modelA	modelB	modelC
16	purelin	learngdm	trainbfg	100	0,00035	0,00032	0,00037
17	logsig	learngd	trainlm	100	0,16968	0,00752	0,00221
17	logsig	learngdm	trainlm	100	0,00879	0,00443	0,00392
17	logsig	learngd	trainbfg	100	0,00760	0,00462	0,00238
17	logsig	learngdm	trainbfg	100	0,00187	0,00204	0,00290
17	tansig	learngd	trainlm	100	0,01251	0,00768	0,01268
17	tansig	learngdm	trainlm	100	0,00378	0,00267	0,00939
17	tansig	learngd	trainbfg	100	0,02352	0,02666	0,03816
17	tansig	learngdm	trainbfg	100	0,00401	0,00608	0,02346
17	purelin	learngd	trainlm	100	0,00030	0,00040	0,00040
17	purelin	learngdm	trainlm	100	0,00059	0,00025	0,00032
17	purelin	learngd	trainbfg	100	0,00015	0,00048	0,00017
17	purelin	learngdm	trainbfg	100	0,00027	0,00119	0,00046
18	logsig	learngd	trainlm	100	0,00119	0,00141	0,00039
18	logsig	learngdm	trainlm	100	0,02469	0,00471	0,00087
18	logsig	learngd	trainbfg	100	0,00362	0,00448	0,00354
18	logsig	learngdm	trainbfg	100	0,01604	0,01762	0,01243
18	tansig	learngd	trainlm	100	0,00125	0,00079	0,00797
18	tansig	learngdm	trainlm	100	0,08075	0,01956	0,05955
18	tansig	learngd	trainbfg	100	0,01475	0,00339	0,00567
18	tansig	learngdm	trainbfg	100	0,00198	0,00139	0,01666
18	purelin	learngd	trainlm	100	0,00045	0,00028	0,00043
18	purelin	learngdm	trainlm	100	0,00011	0,00037	0,00045
18	purelin	learngd	trainbfg	100	0,00038	0,00034	0,00046
18	purelin	learngdm	trainbfg	100	0,00065	0,00112	0,00033

node	active	learn	train	epoch	modelA	modelB	modelC
19	logsig	learngd	trainlm	100	0,01110	0,00324	0,00288
19	logsig	learngdm	trainlm	100	0,02177	0,00732	0,05152
19	logsig	learngd	trainbfg	100	0,00257	0,00251	0,00499
19	logsig	learngdm	trainbfg	100	0,01053	0,00347	0,00744
19	tansig	learngd	trainlm	100	0,04339	0,02139	0,01161
19	tansig	learngdm	trainlm	100	0,00498	0,00281	0,00373
19	tansig	learngd	trainbfg	100	0,00428	0,00254	0,00245
19	tansig	learngdm	trainbfg	100	0,01837	0,03171	0,01884
19	purelin	learngd	trainlm	100	0,00029	0,00020	0,00030
19	purelin	learngdm	trainlm	100	0,00022	0,00024	0,00069
19	purelin	learngd	trainbfg	100	0,00362	0,00025	0,00069
19	purelin	learngdm	trainbfg	100	0,00031	0,00034	0,00025
20	logsig	learngd	trainlm	100	0,01671	0,00216	0,01200
20	logsig	learngdm	trainlm	100	0,00763	0,00750	0,00514
20	logsig	learngd	trainbfg	100	0,01907	0,01367	0,01666
20	logsig	learngdm	trainbfg	100	0,02411	0,01632	0,02736
20	tansig	learngd	trainlm	100	0,00745	0,00491	0,00269
20	tansig	learngdm	trainlm	100	0,03409	0,00471	0,00353
20	tansig	learngd	trainbfg	100	0,00730	0,00353	0,00387
20	tansig	learngdm	trainbfg	100	0,11670	0,13204	0,03229
20	purelin	learngd	trainlm	100	0,00034	0,00064	0,00050
20	purelin	learngdm	trainlm	100	0,00065	0,00049	0,00031
20	purelin	learngd	trainbfg	100	0,00028	0,00022	0,00044
20	purelin	learngdm	trainbfg	100	0,00048	0,00035	0,00024
21	logsig	learngd	trainlm	100	0,01353	0,04354	0,02385

node	active	learn	train	epoch	modelA	modelB	modelC
21	logsig	learngdm	trainlm	100	0,01684	0,05187	0,00579
21	logsig	learngd	trainbfg	100	0,01464	0,02260	0,01874
21	logsig	learngdm	trainbfg	100	0,01036	0,00594	0,00628
21	tansig	learngd	trainlm	100	0,00476	0,00790	0,01547
21	tansig	learngdm	trainlm	100	0,01567	0,00483	0,00803
21	tansig	learngd	trainbfg	100	0,01429	0,00538	0,00425
21	tansig	learngdm	trainbfg	100	0,02454	0,00477	0,04987
21	purelin	learngd	trainlm	100	0,00042	0,00036	0,00036
21	purelin	learngdm	trainlm	100	0,00032	0,00014	0,00028
21	purelin	learngd	trainbfg	100	0,00046	0,00012	0,00024
21	purelin	learngdm	trainbfg	100	0,00024	0,00065	0,00024

3. Periode peramalan 6 bulan

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	0,00029	0,00085	0,00032
2	logsig	learngdm	trainlm	100	0,00123	0,00033	0,00044
2	logsig	learngd	trainbfg	100	0,00476	0,00394	0,00054
2	logsig	learngdm	trainbfg	100	0,00143	0,00118	0,00255
2	tansig	learngd	trainlm	100	0,00245	0,00052	0,00203
2	tansig	learngdm	trainlm	100	0,00066	0,00046	0,00039
2	tansig	learngd	trainbfg	100	0,00262	0,07810	0,00195
2	tansig	learngdm	trainbfg	100	0,00163	0,00134	0,00141
2	purelin	learngd	trainlm	100	0,00064	0,00079	0,00084
2	purelin	learngdm	trainlm	100	0,00050	0,00075	0,00083
2	purelin	learngd	trainbfg	100	0,00305	0,00181	0,00499

node	active	learn	train	epoch	modelA	modelB	modelC
2	purelin	learngdm	trainbfg	100	0,00033	0,00045	0,00060
3	logsig	learngd	trainlm	100	0,00048	0,00119	0,00039
3	logsig	learngdm	trainlm	100	0,00063	0,00042	0,00195
3	logsig	learngd	trainbfg	100	0,00275	0,00134	0,00081
3	logsig	learngdm	trainbfg	100	0,00509	0,00388	0,00305
3	tansig	learngd	trainlm	100	0,00030	0,00080	0,00174
3	tansig	learngdm	trainlm	100	0,00028	0,00176	0,00014
3	tansig	learngd	trainbfg	100	0,00164	0,00129	0,00171
3	tansig	learngdm	trainbfg	100	0,01641	0,00070	0,00179
3	purelin	learngd	trainlm	100	0,00054	0,00061	0,00051
3	purelin	learngdm	trainlm	100	0,00052	0,00053	0,00056
3	purelin	learngd	trainbfg	100	0,00104	0,00141	0,00065
3	purelin	learngdm	trainbfg	100	0,00122	0,00245	0,00064
4	logsig	learngd	trainlm	100	0,00199	0,01010	0,01372
4	logsig	learngdm	trainlm	100	0,00050	0,00068	0,00182
4	logsig	learngd	trainbfg	100	0,00155	0,00287	0,01808
4	logsig	learngdm	trainbfg	100	0,00267	0,00732	0,00783
4	tansig	learngd	trainlm	100	0,00046	0,00608	0,00036
4	tansig	learngdm	trainlm	100	0,00022	0,00019	0,00136
4	tansig	learngd	trainbfg	100	0,00093	0,00108	0,00359
4	tansig	learngdm	trainbfg	100	0,00047	0,00038	0,00062
4	purelin	learngd	trainlm	100	0,00065	0,00048	0,00057
4	purelin	learngdm	trainlm	100	0,00045	0,00049	0,00059
4	purelin	learngd	trainbfg	100	0,00136	0,00056	0,00204
4	purelin	learngdm	trainbfg	100	0,00056	0,00531	0,00061
5	logsig	learngd	trainlm	100	0,00106	0,00108	0,00857
5	logsig	learngdm	trainlm	100	0,00056	0,00142	0,00024
5	logsig	learngd	trainbfg	100	0,00088	0,00130	0,00061

node	active	learn	train	epoch	modelA	modelB	modelC
5	logsig	learngdm	trainbfg	100	0,00358	0,00094	0,00740
5	tansig	learngd	trainlm	100	0,00042	0,00043	0,00058
5	tansig	learngdm	trainlm	100	0,00126	0,00027	0,00021
5	tansig	learngd	trainbfg	100	0,00105	0,00045	0,00092
5	tansig	learngdm	trainbfg	100	0,00297	0,00455	0,00270
5	purelin	learngd	trainlm	100	0,00067	0,00041	0,00064
5	purelin	learngdm	trainlm	100	0,00080	0,00065	0,00064
5	purelin	learngd	trainbfg	100	0,00096	0,00106	0,00080
5	purelin	learngdm	trainbfg	100	0,00095	0,00041	0,00132
6	logsig	learngd	trainlm	100	0,00327	0,00088	0,00063
6	logsig	learngdm	trainlm	100	0,00235	0,00037	0,00029
6	logsig	learngd	trainbfg	100	0,00566	0,00185	0,00500
6	logsig	learngdm	trainbfg	100	0,00083	0,00187	0,00118
6	tansig	learngd	trainlm	100	0,00281	0,00129	0,00092
6	tansig	learngdm	trainlm	100	0,00056	0,00039	0,00039
6	tansig	learngd	trainbfg	100	0,00144	0,00613	0,00174
6	tansig	learngdm	trainbfg	100	0,00487	0,00284	0,00370
6	purelin	learngd	trainlm	100	0,00058	0,00060	0,00044
6	purelin	learngdm	trainlm	100	0,00047	0,00067	0,00051
6	purelin	learngd	trainbfg	100	0,00170	0,00082	0,00084
6	purelin	learngdm	trainbfg	100	0,00278	0,00096	0,00115
7	logsig	learngd	trainlm	100	0,00861	0,00410	0,00322
7	logsig	learngdm	trainlm	100	0,00782	0,00262	0,00161
7	logsig	learngd	trainbfg	100	0,00054	0,00338	0,01162
7	logsig	learngdm	trainbfg	100	0,00720	0,00270	0,00424
7	tansig	learngd	trainlm	100	0,00200	0,01738	0,00128
7	tansig	learngdm	trainlm	100	0,00358	0,00037	0,00041
7	tansig	learngd	trainbfg	100	0,00362	0,04624	0,00241

node	active	learn	train	epoch	modelA	modelB	modelC
7	tansig	learngdm	trainbfg	100	0,00330	0,00227	0,00309
7	purelin	learngd	trainlm	100	0,00048	0,00047	0,00057
7	purelin	learngdm	trainlm	100	0,00054	0,00050	0,00048
7	purelin	learngd	trainbfg	100	0,00042	0,00050	0,00074
7	purelin	learngdm	trainbfg	100	0,00092	0,00282	0,00059
8	logsig	learngd	trainlm	100	0,00123	0,00125	0,00063
8	logsig	learngdm	trainlm	100	0,00485	0,00545	0,02128
8	logsig	learngd	trainbfg	100	0,01029	0,00311	0,00553
8	logsig	learngdm	trainbfg	100	0,00231	0,00362	0,00225
8	tansig	learngd	trainlm	100	0,00156	0,00030	0,00752
8	tansig	learngdm	trainlm	100	0,00143	0,00200	0,00137
8	tansig	learngd	trainbfg	100	0,00196	0,01173	0,00644
8	tansig	learngdm	trainbfg	100	0,00219	0,00097	0,00138
8	purelin	learngd	trainlm	100	0,00041	0,00042	0,00061
8	purelin	learngdm	trainlm	100	0,00055	0,00064	0,00071
8	purelin	learngd	trainbfg	100	0,00127	0,00060	0,00067
8	purelin	learngdm	trainbfg	100	0,00060	0,00053	0,00067
9	logsig	learngd	trainlm	100	0,00311	0,01008	0,00745
9	logsig	learngdm	trainlm	100	0,00026	0,06919	0,19888
9	logsig	learngd	trainbfg	100	0,01869	0,01168	0,03236
9	logsig	learngdm	trainbfg	100	0,00831	0,00779	0,00509
9	tansig	learngd	trainlm	100	0,00174	0,03950	0,00343
9	tansig	learngdm	trainlm	100	0,00045	0,05747	0,02246
9	tansig	learngd	trainbfg	100	0,01851	0,00595	0,01164
9	tansig	learngdm	trainbfg	100	0,00403	0,00122	0,00324
9	purelin	learngd	trainlm	100	0,00068	0,00040	0,00055
9	purelin	learngdm	trainlm	100	0,00055	0,00053	0,00059
9	purelin	learngd	trainbfg	100	0,00087	0,00114	0,00046

node	active	learn	train	epoch	modelA	modelB	modelC
9	purelin	learngdm	trainbfg	100	0,00056	0,00158	0,00054
10	logsig	learngd	trainlm	100	0,00199	0,02012	0,00033
10	logsig	learngdm	trainlm	100	0,00613	0,05198	0,00257
10	logsig	learngd	trainbfg	100	0,00366	0,00506	0,01504
10	logsig	learngdm	trainbfg	100	0,00308	0,00185	0,00092
10	tansig	learngd	trainlm	100	0,00292	0,28466	0,02447
10	tansig	learngdm	trainlm	100	0,00925	0,00194	0,02121
10	tansig	learngd	trainbfg	100	0,01022	0,01516	0,01256
10	tansig	learngdm	trainbfg	100	0,00046	0,00059	0,00084
10	purelin	learngd	trainlm	100	0,00056	0,00085	0,00067
10	purelin	learngdm	trainlm	100	0,00055	0,00038	0,00065
10	purelin	learngd	trainbfg	100	0,00033	0,00065	0,00371
10	purelin	learngdm	trainbfg	100	0,00078	0,00085	0,00185
11	logsig	learngd	trainlm	100	0,00266	0,00201	0,00369
11	logsig	learngdm	trainlm	100	0,00157	0,00155	0,00089
11	logsig	learngd	trainbfg	100	0,00365	0,00434	0,00326
11	logsig	learngdm	trainbfg	100	0,00379	0,00991	0,00572
11	tansig	learngd	trainlm	100	0,00672	0,00437	0,03073
11	tansig	learngdm	trainlm	100	0,00186	0,01425	0,00254
11	tansig	learngd	trainbfg	100	0,00274	0,00312	0,02002
11	tansig	learngdm	trainbfg	100	0,01321	0,01286	0,00228
11	purelin	learngd	trainlm	100	0,00075	0,00061	0,00058
11	purelin	learngdm	trainlm	100	0,00042	0,00046	0,00068
11	purelin	learngd	trainbfg	100	0,00184	0,00059	0,00145
11	purelin	learngdm	trainbfg	100	0,00077	0,00083	0,00123
12	logsig	learngd	trainlm	100	0,01053	0,01094	0,00254
12	logsig	learngdm	trainlm	100	0,00123	0,00041	0,00139
12	logsig	learngd	trainbfg	100	0,00070	0,00057	0,00618

node	active	learn	train	epoch	modelA	modelB	modelC
12	logsig	learngdm	trainbfg	100	0,00281	0,00389	0,00441
12	tansig	learngd	trainlm	100	0,00534	0,00575	0,01497
12	tansig	learngdm	trainlm	100	0,01521	0,00946	0,00054
12	tansig	learngd	trainbfg	100	0,00203	0,00762	0,00344
12	tansig	learngdm	trainbfg	100	0,00666	0,00925	0,00468
12	purelin	learngd	trainlm	100	0,00063	0,00045	0,00046
12	purelin	learngdm	trainlm	100	0,00065	0,00050	0,00076
12	purelin	learngd	trainbfg	100	0,00187	0,00169	0,00127
12	purelin	learngdm	trainbfg	100	0,00120	0,00059	0,00126
13	logsig	learngd	trainlm	100	0,01108	0,01804	0,00535
13	logsig	learngdm	trainlm	100	0,00526	0,00648	0,04212
13	logsig	learngd	trainbfg	100	0,00096	0,00294	0,00226
13	logsig	learngdm	trainbfg	100	0,00458	0,00744	0,01438
13	tansig	learngd	trainlm	100	0,00085	0,07020	0,00143
13	tansig	learngdm	trainlm	100	0,00043	0,00111	0,00131
13	tansig	learngd	trainbfg	100	0,00541	0,00134	0,00999
13	tansig	learngdm	trainbfg	100	0,00197	0,00122	0,02737
13	purelin	learngd	trainlm	100	0,00068	0,00099	0,00077
13	purelin	learngdm	trainlm	100	0,00046	0,00070	0,00059
13	purelin	learngd	trainbfg	100	0,00117	0,00075	0,00138
13	purelin	learngdm	trainbfg	100	0,00066	0,00046	0,00072
14	logsig	learngd	trainlm	100	0,01128	0,00388	0,00266
14	logsig	learngdm	trainlm	100	0,00713	0,00105	0,00373
14	logsig	learngd	trainbfg	100	0,00499	0,00733	0,00342
14	logsig	learngdm	trainbfg	100	0,00134	0,00189	0,00262
14	tansig	learngd	trainlm	100	0,23393	0,00312	0,03132
14	tansig	learngdm	trainlm	100	0,01477	0,00134	0,00740
14	tansig	learngd	trainbfg	100	0,00161	0,00865	0,02303

node	active	learn	train	epoch	modelA	modelB	modelC
14	tansig	learngdm	trainbfg	100	0,00519	0,00353	0,00152
14	purelin	learngd	trainlm	100	0,00066	0,00059	0,00077
14	purelin	learngdm	trainlm	100	0,00071	0,00053	0,00134
14	purelin	learngd	trainbfg	100	0,00075	0,00167	0,00206
14	purelin	learngdm	trainbfg	100	0,00104	0,00072	0,00136
15	logsig	learngd	trainlm	100	0,00962	0,00281	0,00184
15	logsig	learngdm	trainlm	100	0,01139	0,03767	0,05104
15	logsig	learngd	trainbfg	100	0,00406	0,00928	0,01959
15	logsig	learngdm	trainbfg	100	0,00518	0,00386	0,00447
15	tansig	learngd	trainlm	100	0,00298	0,01078	0,00160
15	tansig	learngdm	trainlm	100	0,00377	0,00384	0,00275
15	tansig	learngd	trainbfg	100	0,00593	0,00478	0,00984
15	tansig	learngdm	trainbfg	100	0,00070	0,00364	0,00554
15	purelin	learngd	trainlm	100	0,00064	0,00063	0,00049
15	purelin	learngdm	trainlm	100	0,00038	0,00092	0,00058
15	purelin	learngd	trainbfg	100	0,00210	0,00067	0,00173
15	purelin	learngdm	trainbfg	100	0,00112	0,00060	0,00091
16	logsig	learngd	trainlm	100	0,00182	0,00109	0,00262
16	logsig	learngdm	trainlm	100	0,00514	0,02095	0,00607
16	logsig	learngd	trainbfg	100	0,00553	0,00388	0,00407
16	logsig	learngdm	trainbfg	100	0,02762	0,00437	0,00747
16	tansig	learngd	trainlm	100	0,00458	0,01061	0,00421
16	tansig	learngdm	trainlm	100	0,00816	0,00604	0,00350
16	tansig	learngd	trainbfg	100	0,00762	0,04024	0,02408
16	tansig	learngdm	trainbfg	100	0,02931	0,01422	0,01219
16	purelin	learngd	trainlm	100	0,00063	0,00052	0,00054
16	purelin	learngdm	trainlm	100	0,00062	0,00066	0,00066
16	purelin	learngd	trainbfg	100	0,00112	0,00056	0,00050

node	active	learn	train	epoch	modelA	modelB	modelC
16	purelin	learngdm	trainbfg	100	0,00053	0,00061	0,00074
17	logsig	learngd	trainlm	100	0,00257	0,00741	0,03372
17	logsig	learngdm	trainlm	100	0,18435	0,00355	0,00190
17	logsig	learngd	trainbfg	100	0,00138	0,00566	0,00334
17	logsig	learngdm	trainbfg	100	0,00565	0,00596	0,00776
17	tansig	learngd	trainlm	100	0,01070	0,00517	0,00607
17	tansig	learngdm	trainlm	100	0,00268	0,00941	0,00219
17	tansig	learngd	trainbfg	100	0,02046	0,00279	0,01683
17	tansig	learngdm	trainbfg	100	0,01302	0,01637	0,01282
17	purelin	learngd	trainlm	100	0,00060	0,00092	0,00051
17	purelin	learngdm	trainlm	100	0,00058	0,00049	0,00055
17	purelin	learngd	trainbfg	100	0,00090	0,00055	0,00282
17	purelin	learngdm	trainbfg	100	0,00073	0,00067	0,00300
18	logsig	learngd	trainlm	100	0,00246	0,00327	0,00231
18	logsig	learngdm	trainlm	100	0,02686	0,17514	0,00112
18	logsig	learngd	trainbfg	100	0,00995	0,00346	0,00541
18	logsig	learngdm	trainbfg	100	0,00117	0,00178	0,00640
18	tansig	learngd	trainlm	100	0,01365	0,00821	0,00326
18	tansig	learngdm	trainlm	100	0,04640	0,00551	0,08953
18	tansig	learngd	trainbfg	100	0,00254	0,00315	0,00476
18	tansig	learngdm	trainbfg	100	0,01068	0,00536	0,00368
18	purelin	learngd	trainlm	100	0,00065	0,00080	0,00055
18	purelin	learngdm	trainlm	100	0,00077	0,00085	0,00044
18	purelin	learngd	trainbfg	100	0,00298	0,00077	0,00092
18	purelin	learngdm	trainbfg	100	0,00055	0,00047	0,00062
19	logsig	learngd	trainlm	100	0,00363	0,00289	0,01701
19	logsig	learngdm	trainlm	100	0,00148	0,00555	0,00300
19	logsig	learngd	trainbfg	100	0,00358	0,00123	0,00131

node	active	learn	train	epoch	modelA	modelB	modelC
19	logsig	learngdm	trainbfg	100	0,01074	0,01335	0,01271
19	tansig	learngd	trainlm	100	0,01903	0,04111	0,00951
19	tansig	learngdm	trainlm	100	0,00376	0,03522	0,00301
19	tansig	learngd	trainbfg	100	0,01745	0,00523	0,00383
19	tansig	learngdm	trainbfg	100	0,00585	0,00822	0,00125
19	purelin	learngd	trainlm	100	0,00050	0,00052	0,00058
19	purelin	learngdm	trainlm	100	0,00081	0,00074	0,00076
19	purelin	learngd	trainbfg	100	0,00053	0,00080	0,00049
19	purelin	learngdm	trainbfg	100	0,00185	0,00072	0,00104
20	logsig	learngd	trainlm	100	0,00308	0,00410	0,00270
20	logsig	learngdm	trainlm	100	0,00631	0,00846	0,01438
20	logsig	learngd	trainbfg	100	0,00288	0,00171	0,00349
20	logsig	learngdm	trainbfg	100	0,00754	0,00293	0,00305
20	tansig	learngd	trainlm	100	0,01833	0,00617	0,02716
20	tansig	learngdm	trainlm	100	0,00420	0,03929	0,12928
20	tansig	learngd	trainbfg	100	0,01610	0,01653	0,02605
20	tansig	learngdm	trainbfg	100	0,00329	0,00607	0,00286
20	purelin	learngd	trainlm	100	0,00047	0,00065	0,00045
20	purelin	learngdm	trainlm	100	0,00059	0,00056	0,00059
20	purelin	learngd	trainbfg	100	0,00158	0,00070	0,00046
20	purelin	learngdm	trainbfg	100	0,00090	0,00196	0,00080
21	logsig	learngd	trainlm	100	0,01345	0,01057	0,01991
21	logsig	learngdm	trainlm	100	0,00183	0,00432	0,00712
21	logsig	learngd	trainbfg	100	0,00348	0,00300	0,00433
21	logsig	learngdm	trainbfg	100	0,00928	0,01091	0,01470
21	tansig	learngd	trainlm	100	0,01041	0,00827	0,02067
21	tansig	learngdm	trainlm	100	0,00474	0,01371	0,00661
21	tansig	learngd	trainbfg	100	0,00487	0,02021	0,01964

node	active	learn	train	epoch	modelA	modelB	modelC
21	tansig	learngdm	trainbfg	100	0,01421	0,02181	0,03195
21	purelin	learngd	trainlm	100	0,00060	0,00063	0,00067
21	purelin	learngdm	trainlm	100	0,00046	0,00054	0,00051
21	purelin	learngd	trainbfg	100	0,00065	0,00037	0,00060
21	purelin	learngdm	trainbfg	100	0,00418	0,00072	0,00090

4. Periode peramalan 12 bulan

node	active	learn	train	epoch	modelA	modelB	modelC
2	logsig	learngd	trainlm	100	0,00048	0,00073	0,00409
2	logsig	learngdm	trainlm	100	0,00045	0,00097	0,00039
2	logsig	learngd	trainbfg	100	0,00995	0,00301	0,01030
2	logsig	learngdm	trainbfg	100	0,00424	0,00362	0,00237
2	tansig	learngd	trainlm	100	0,00437	0,01058	0,01210
2	tansig	learngdm	trainlm	100	0,00103	0,00095	0,00119
2	tansig	learngd	trainbfg	100	0,00287	0,00138	0,00335
2	tansig	learngdm	trainbfg	100	0,00495	0,00613	0,00420
2	purelin	learngd	trainlm	100	0,00099	0,00136	0,00123
2	purelin	learngdm	trainlm	100	0,00199	0,00104	0,00088
2	purelin	learngd	trainbfg	100	0,00183	0,00131	0,00503
2	purelin	learngdm	trainbfg	100	0,00526	0,00210	0,00179
3	logsig	learngd	trainlm	100	0,00234	0,00023	0,00134
3	logsig	learngdm	trainlm	100	0,00448	0,02047	0,00045
3	logsig	learngd	trainbfg	100	0,00088	0,00206	0,00254
3	logsig	learngdm	trainbfg	100	0,00498	0,00559	0,00574
3	tansig	learngd	trainlm	100	0,00143	0,00096	0,00218
3	tansig	learngdm	trainlm	100	0,00248	0,00095	0,00109

node	active	learn	train	epoch	modelA	modelB	modelC
3	tansig	learngd	trainbfg	100	0,00425	0,00317	0,00347
3	tansig	learngdm	trainbfg	100	0,00358	0,00381	0,00319
3	purelin	learngd	trainlm	100	0,00128	0,00101	0,00097
3	purelin	learngdm	trainlm	100	0,00121	0,00115	0,00117
3	purelin	learngd	trainbfg	100	0,00144	0,00209	0,00185
3	purelin	learngdm	trainbfg	100	0,00377	0,00299	0,00171
4	logsig	learngd	trainlm	100	0,00109	0,00073	0,00396
4	logsig	learngdm	trainlm	100	0,00072	0,00047	0,00034
4	logsig	learngd	trainbfg	100	0,00176	0,00199	0,00293
4	logsig	learngdm	trainbfg	100	0,00263	0,00225	0,00403
4	tansig	learngd	trainlm	100	0,00114	0,00175	0,00064
4	tansig	learngdm	trainlm	100	0,00124	0,00089	0,00047
4	tansig	learngd	trainbfg	100	0,00314	0,00224	0,00444
4	tansig	learngdm	trainbfg	100	0,00251	0,00193	0,00229
4	purelin	learngd	trainlm	100	0,00098	0,00131	0,00098
4	purelin	learngdm	trainlm	100	0,00219	0,00231	0,00204
4	purelin	learngd	trainbfg	100	0,00215	0,00198	0,00115
4	purelin	learngdm	trainbfg	100	0,00109	0,00152	0,00121
5	logsig	learngd	trainlm	100	0,00128	0,00054	0,00103
5	logsig	learngdm	trainlm	100	0,00459	0,00376	0,00060
5	logsig	learngd	trainbfg	100	0,00185	0,00204	0,00244
5	logsig	learngdm	trainbfg	100	0,00155	0,00327	0,00335
5	tansig	learngd	trainlm	100	0,00218	0,00028	0,00055
5	tansig	learngdm	trainlm	100	0,00124	0,00545	0,00031
5	tansig	learngd	trainbfg	100	0,00681	0,00370	0,00285
5	tansig	learngdm	trainbfg	100	0,00183	0,00212	0,00227
5	purelin	learngd	trainlm	100	0,00121	0,00127	0,00144
5	purelin	learngdm	trainlm	100	0,00095	0,00095	0,00204

node	active	learn	train	epoch	modelA	modelB	modelC
5	purelin	learngd	trainbfg	100	0,00186	0,00313	0,00216
5	purelin	learngdm	trainbfg	100	0,00115	0,00104	0,00162
6	logsig	learngd	trainlm	100	0,00165	0,00192	0,00041
6	logsig	learngdm	trainlm	100	0,00138	0,00568	0,00092
6	logsig	learngd	trainbfg	100	0,00519	0,00444	0,00460
6	logsig	learngdm	trainbfg	100	0,00222	0,00230	0,00226
6	tansig	learngd	trainlm	100	0,00726	0,00378	0,00959
6	tansig	learngdm	trainlm	100	0,00496	0,03617	0,00696
6	tansig	learngd	trainbfg	100	0,00237	0,00226	0,00452
6	tansig	learngdm	trainbfg	100	0,00279	0,00370	0,00326
6	purelin	learngd	trainlm	100	0,00156	0,00126	0,00085
6	purelin	learngdm	trainlm	100	0,00101	0,00112	0,00154
6	purelin	learngd	trainbfg	100	0,00111	0,00154	0,00206
6	purelin	learngdm	trainbfg	100	0,00097	0,00137	0,00108
7	logsig	learngd	trainlm	100	0,00635	0,00310	0,00758
7	logsig	learngdm	trainlm	100	0,00109	0,00183	0,00162
7	logsig	learngd	trainbfg	100	0,00171	0,00083	0,00128
7	logsig	learngdm	trainbfg	100	0,00290	0,01689	0,02997
7	tansig	learngd	trainlm	100	0,00388	0,00275	0,00087
7	tansig	learngdm	trainlm	100	0,00255	0,01828	0,00350
7	tansig	learngd	trainbfg	100	0,00262	0,00264	0,00447
7	tansig	learngdm	trainbfg	100	0,00230	0,00548	0,00791
7	purelin	learngd	trainlm	100	0,00129	0,00149	0,00143
7	purelin	learngdm	trainlm	100	0,00145	0,00093	0,00096
7	purelin	learngd	trainbfg	100	0,00171	0,00167	0,00121
7	purelin	learngdm	trainbfg	100	0,00175	0,00120	0,00111
8	logsig	learngd	trainlm	100	0,00091	0,00053	0,00492
8	logsig	learngdm	trainlm	100	0,00458	0,02063	0,00236

node	active	learn	train	epoch	modelA	modelB	modelC
8	logsig	learngd	trainbfg	100	0,02307	0,00241	0,00408
8	logsig	learngdm	trainbfg	100	0,00340	0,00314	0,00337
8	tansig	learngd	trainlm	100	0,00507	0,00165	0,00752
8	tansig	learngdm	trainlm	100	0,00083	0,00644	0,00123
8	tansig	learngd	trainbfg	100	0,01243	0,00496	0,01189
8	tansig	learngdm	trainbfg	100	0,00344	0,02447	0,02855
8	purelin	learngd	trainlm	100	0,00139	0,00140	0,00121
8	purelin	learngdm	trainlm	100	0,00137	0,00128	0,00107
8	purelin	learngd	trainbfg	100	0,00135	0,00167	0,00268
8	purelin	learngdm	trainbfg	100	0,00185	0,00222	0,00118
9	logsig	learngd	trainlm	100	0,00276	0,00232	0,00440
9	logsig	learngdm	trainlm	100	0,01638	0,00388	0,00139
9	logsig	learngd	trainbfg	100	0,02008	0,00368	0,00339
9	logsig	learngdm	trainbfg	100	0,00573	0,00417	0,00366
9	tansig	learngd	trainlm	100	0,00044	0,00284	0,00080
9	tansig	learngdm	trainlm	100	0,00164	0,01126	0,00074
9	tansig	learngd	trainbfg	100	0,01143	0,00587	0,00978
9	tansig	learngdm	trainbfg	100	0,00576	0,00590	0,00418
9	purelin	learngd	trainlm	100	0,00131	0,00105	0,00132
9	purelin	learngdm	trainlm	100	0,00153	0,00129	0,00141
9	purelin	learngd	trainbfg	100	0,00296	0,00296	0,00114
9	purelin	learngdm	trainbfg	100	0,00424	0,00174	0,00121
10	logsig	learngd	trainlm	100	0,00051	0,00167	0,01034
10	logsig	learngdm	trainlm	100	0,00594	0,00177	0,00190
10	logsig	learngd	trainbfg	100	0,00378	0,00427	0,00132
10	logsig	learngdm	trainbfg	100	0,00680	0,02040	0,00938
10	tansig	learngd	trainlm	100	0,01062	0,00340	0,01274
10	tansig	learngdm	trainlm	100	0,02749	0,00400	0,00097

node	active	learn	train	epoch	modelA	modelB	modelC
10	tansig	learngd	trainbfg	100	0,00220	0,01742	0,00683
10	tansig	learngdm	trainbfg	100	0,00285	0,00327	0,00441
10	purelin	learngd	trainlm	100	0,00165	0,00099	0,00124
10	purelin	learngdm	trainlm	100	0,00114	0,00184	0,00102
10	purelin	learngd	trainbfg	100	0,00262	0,00205	0,00239
10	purelin	learngdm	trainbfg	100	0,00169	0,00098	0,00160
11	logsig	learngd	trainlm	100	0,00533	0,03501	0,01271
11	logsig	learngdm	trainlm	100	0,00276	0,00621	0,02418
11	logsig	learngd	trainbfg	100	0,00113	0,00517	0,00113
11	logsig	learngdm	trainbfg	100	0,00798	0,01227	0,01325
11	tansig	learngd	trainlm	100	0,00564	0,00115	0,00133
11	tansig	learngdm	trainlm	100	0,00104	0,00055	0,00448
11	tansig	learngd	trainbfg	100	0,00672	0,00347	0,00436
11	tansig	learngdm	trainbfg	100	0,00392	0,00319	0,00159
11	purelin	learngd	trainlm	100	0,00161	0,00236	0,00110
11	purelin	learngdm	trainlm	100	0,00138	0,00132	0,00141
11	purelin	learngd	trainbfg	100	0,00101	0,00230	0,00169
11	purelin	learngdm	trainbfg	100	0,00157	0,00278	0,00115
12	logsig	learngd	trainlm	100	0,00150	0,00139	0,00396
12	logsig	learngdm	trainlm	100	0,00165	0,01070	0,00392
12	logsig	learngd	trainbfg	100	0,00308	0,00286	0,00280
12	logsig	learngdm	trainbfg	100	0,00386	0,00407	0,00638
12	tansig	learngd	trainlm	100	0,00188	0,00595	0,00827
12	tansig	learngdm	trainlm	100	0,00546	0,00101	0,00099
12	tansig	learngd	trainbfg	100	0,00401	0,00400	0,00492
12	tansig	learngdm	trainbfg	100	0,00144	0,00149	0,00238
12	purelin	learngd	trainlm	100	0,00129	0,00115	0,00101
12	purelin	learngdm	trainlm	100	0,00100	0,00106	0,00126

node	active	learn	train	epoch	modelA	modelB	modelC
12	purelin	learngd	trainbfg	100	0,00267	0,00099	0,00103
12	purelin	learngdm	trainbfg	100	0,00127	0,00151	0,00178
13	logsig	learngd	trainlm	100	0,00334	0,03066	0,00480
13	logsig	learngdm	trainlm	100	0,00432	0,00670	0,00311
13	logsig	learngd	trainbfg	100	0,00287	0,01483	0,00221
13	logsig	learngdm	trainbfg	100	0,01202	0,00472	0,03000
13	tansig	learngd	trainlm	100	0,00274	0,00365	0,00888
13	tansig	learngdm	trainlm	100	0,00481	0,00565	0,00207
13	tansig	learngd	trainbfg	100	0,00168	0,00297	0,02367
13	tansig	learngdm	trainbfg	100	0,00418	0,00337	0,00631
13	purelin	learngd	trainlm	100	0,00148	0,00106	0,00126
13	purelin	learngdm	trainlm	100	0,00417	0,00073	0,00089
13	purelin	learngd	trainbfg	100	0,00157	0,00121	0,00321
13	purelin	learngdm	trainbfg	100	0,00151	0,00165	0,00179
14	logsig	learngd	trainlm	100	0,00718	0,00236	0,00660
14	logsig	learngdm	trainlm	100	0,00336	0,00216	0,00227
14	logsig	learngd	trainbfg	100	0,01164	0,00750	0,00540
14	logsig	learngdm	trainbfg	100	0,00167	0,01020	0,00213
14	tansig	learngd	trainlm	100	0,00124	0,00321	0,00069
14	tansig	learngdm	trainlm	100	0,00201	0,00120	0,00477
14	tansig	learngd	trainbfg	100	0,00840	0,00372	0,00319
14	tansig	learngdm	trainbfg	100	0,00433	0,00357	0,00257
14	purelin	learngd	trainlm	100	0,00253	0,00123	0,00096
14	purelin	learngdm	trainlm	100	0,00138	0,00136	0,00119
14	purelin	learngd	trainbfg	100	0,00208	0,00247	0,00612
14	purelin	learngdm	trainbfg	100	0,00330	0,00132	0,00123
15	logsig	learngd	trainlm	100	0,01248	0,01155	0,00154
15	logsig	learngdm	trainlm	100	0,00308	0,00522	0,00200

node	active	learn	train	epoch	modelA	modelB	modelC
15	logsig	learngd	trainbfg	100	0,00604	0,00579	0,00632
15	logsig	learngdm	trainbfg	100	0,01648	0,00752	0,00334
15	tansig	learngd	trainlm	100	0,00373	0,00132	0,00925
15	tansig	learngdm	trainlm	100	0,00452	0,00359	0,00103
15	tansig	learngd	trainbfg	100	0,01231	0,00798	0,00426
15	tansig	learngdm	trainbfg	100	0,00371	0,00583	0,00881
15	purelin	learngd	trainlm	100	0,00088	0,00207	0,00108
15	purelin	learngdm	trainlm	100	0,00157	0,00165	0,00244
15	purelin	learngd	trainbfg	100	0,00201	0,00128	0,00228
15	purelin	learngdm	trainbfg	100	0,00209	0,00227	0,00126
16	logsig	learngd	trainlm	100	0,00475	0,00149	0,01524
16	logsig	learngdm	trainlm	100	0,00221	0,00387	0,00253
16	logsig	learngd	trainbfg	100	0,00296	0,00488	0,01379
16	logsig	learngdm	trainbfg	100	0,00090	0,00188	0,00107
16	tansig	learngd	trainlm	100	0,00112	0,00104	0,00404
16	tansig	learngdm	trainlm	100	0,00057	0,00190	0,00059
16	tansig	learngd	trainbfg	100	0,00287	0,00218	0,00286
16	tansig	learngdm	trainbfg	100	0,00366	0,00309	0,00457
16	purelin	learngd	trainlm	100	0,00145	0,00137	0,00126
16	purelin	learngdm	trainlm	100	0,00151	0,00118	0,00136
16	purelin	learngd	trainbfg	100	0,00187	0,00179	0,00238
16	purelin	learngdm	trainbfg	100	0,00110	0,00059	0,00118
17	logsig	learngd	trainlm	100	0,00156	0,00485	0,00246
17	logsig	learngdm	trainlm	100	0,00433	0,00380	0,00036
17	logsig	learngd	trainbfg	100	0,01018	0,00272	0,00298
17	logsig	learngdm	trainbfg	100	0,01201	0,00660	0,00543
17	tansig	learngd	trainlm	100	0,00123	0,00407	0,00191
17	tansig	learngdm	trainlm	100	0,00386	0,00085	0,00521

node	active	learn	train	epoch	modelA	modelB	modelC
17	tansig	learngd	trainbfg	100	0,00192	0,00332	0,00355
17	tansig	learngdm	trainbfg	100	0,00919	0,00848	0,00995
17	purelin	learngd	trainlm	100	0,00119	0,00100	0,00098
17	purelin	learngdm	trainlm	100	0,00134	0,00138	0,00124
17	purelin	learngd	trainbfg	100	0,00269	0,00109	0,00122
17	purelin	learngdm	trainbfg	100	0,00119	0,00160	0,00126
18	logsig	learngd	trainlm	100	0,05921	0,00847	0,00507
18	logsig	learngdm	trainlm	100	0,01029	0,00973	0,00206
18	logsig	learngd	trainbfg	100	0,00745	0,00762	0,00602
18	logsig	learngdm	trainbfg	100	0,00737	0,00276	0,00750
18	tansig	learngd	trainlm	100	0,01854	0,00384	0,01579
18	tansig	learngdm	trainlm	100	0,00131	0,00214	0,00221
18	tansig	learngd	trainbfg	100	0,01199	0,01424	0,00792
18	tansig	learngdm	trainbfg	100	0,00384	0,00217	0,00512
18	purelin	learngd	trainlm	100	0,00125	0,00137	0,00141
18	purelin	learngdm	trainlm	100	0,00221	0,00163	0,00140
18	purelin	learngd	trainbfg	100	0,00185	0,00212	0,00089
18	purelin	learngdm	trainbfg	100	0,00130	0,00113	0,00144
19	logsig	learngd	trainlm	100	0,01406	0,00754	0,00980
19	logsig	learngdm	trainlm	100	0,00666	0,00887	0,01069
19	logsig	learngd	trainbfg	100	0,00138	0,00697	0,00439
19	logsig	learngdm	trainbfg	100	0,00421	0,00440	0,00263
19	tansig	learngd	trainlm	100	0,00502	0,00161	0,00816
19	tansig	learngdm	trainlm	100	0,00227	0,00115	0,00137
19	tansig	learngd	trainbfg	100	0,00314	0,00208	0,00321
19	tansig	learngdm	trainbfg	100	0,00618	0,00719	0,00734
19	purelin	learngd	trainlm	100	0,00249	0,00146	0,00106
19	purelin	learngdm	trainlm	100	0,00102	0,00139	0,00146

node	active	learn	train	epoch	modelA	modelB	modelC
19	purelin	learngd	trainbfg	100	0,00220	0,00162	0,00116
19	purelin	learngdm	trainbfg	100	0,00113	0,00150	0,00180
20	logsig	learngd	trainlm	100	0,01331	0,00846	0,01654
20	logsig	learngdm	trainlm	100	0,00282	0,00241	0,00356
20	logsig	learngd	trainbfg	100	0,00260	0,00267	0,00269
20	logsig	learngdm	trainbfg	100	0,00174	0,00345	0,00134
20	tansig	learngd	trainlm	100	0,00133	0,00114	0,00831
20	tansig	learngdm	trainlm	100	0,00412	0,00759	0,01659
20	tansig	learngd	trainbfg	100	0,01549	0,00310	0,01248
20	tansig	learngdm	trainbfg	100	0,00711	0,00515	0,00735
20	purelin	learngd	trainlm	100	0,00127	0,00146	0,00082
20	purelin	learngdm	trainlm	100	0,00110	0,00081	0,00097
20	purelin	learngd	trainbfg	100	0,00158	0,00115	0,00128
20	purelin	learngdm	trainbfg	100	0,00312	0,00340	0,00166
21	logsig	learngd	trainlm	100	0,00104	0,00261	0,00053
21	logsig	learngdm	trainlm	100	0,01018	0,01383	0,01706
21	logsig	learngd	trainbfg	100	0,00340	0,00363	0,00320
21	logsig	learngdm	trainbfg	100	0,00726	0,01116	0,01287
21	tansig	learngd	trainlm	100	0,00817	0,00868	0,00136
21	tansig	learngdm	trainlm	100	0,00463	0,00562	0,00984
21	tansig	learngd	trainbfg	100	0,00371	0,00760	0,00148
21	tansig	learngdm	trainbfg	100	0,01567	0,01314	0,00597
21	purelin	learngd	trainlm	100	0,00133	0,00108	0,00102
21	purelin	learngdm	trainlm	100	0,00124	0,00204	0,00097
21	purelin	learngd	trainbfg	100	0,00162	0,00185	0,00202
21	purelin	learngdm	trainbfg	100	0,00132	0,00196	0,00189