



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS141501

**PERAMALAN INDEKS HARGA SAHAM GABUNGAN
INDONESIA DENGAN MENGGUNAKAN METODE
ARTIFICIAL NEURAL NETWORK ALGORITMA
*BACKPROPAGATION***

***FORECASTING INDONESIAN COMPOSITE INDEX
WITH ARTIFICIAL NEURAL NETWORK
BACKPROPAGATION ALGORITHM***

ALDO CHANDRA PURNOMO
NRP 05211440000028

Dosen Pembimbing
Edwin Riksakomara, S.Kom, MT

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

TUGAS AKHIR - KS141501

**Peramalan Indeks Harga Saham Gabungan
Indonesia Dengan Menggunakan Metode *Artificial
Neural Network* Algoritma *Backpropagation***

ALDO CHANDRA PURNOMO
NRP 0521144000028

Dosen Pembimbing
Edwin Riksakomara, S.Kom, MT

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



FINAL PROJECT - KS141501

***FORECASTING INDONESIAN COMPOSITE INDEX
WITH ARTIFICIAL NEURAL NETWORK
BACKPROPAGATION ALGORITHM***

ALDO CHANDRA PURNOMO
NRP 05211440000028

Supervisor
Edwin Riksakomara, S.Kom, MT

INFORMATION SYSTEMS DEPARTMENT
Information Technology and Communication Faculty
Sepuluh Nopember Institute of Technology
Surabaya 2018

LEMBAR PENGESAHAN
PERAMALAN INDEKS HARGA SAHAM
GABUNGAN INDONESIA DENGAN
MENGGUNAKAN METODE *ARTIFICIAL*
***NEURAL NETWORK* ALGORITMA**
BACKPROPAGATION

TUGAS AKHIR

Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember

Oleh :

ALDO CHANDRA PURNOMO
NRP 05211440000028

Surabaya, Juli 2018

KEPALA
DEPARTEMEN SISTEM INFORMASI

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

LEMBAR PERSETUJUAN

PERAMALAN INDEKS HARGA SAHAM GABUNGAN INDONESIA DENGAN MENGUNAKAN METODE *ARTIFICIAL NEURAL NETWORK* ALGORITMA *BACKPROPAGATION*

TUGAS AKHIR

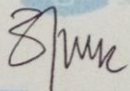
Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Jurusan Sistem Informasi
Fakultas Teknologi Informasi dan Komunikasi
Institut Teknologi Sepuluh Nopember

Oleh :

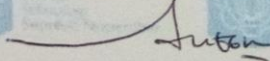
ALDO CHANDRA PURNOMO
NRP 05211440000028

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

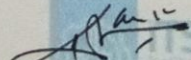
Edwin Riksakomara, S.Kom, MT


(Pembimbing I)

Wiwik Anggraeni, S.SI, M.Kom


(Penguji I)

Faizal Mahananto, S.Kom, M.Eng


(Penguji II)

**PERAMALAN INDEKS HARGA SAHAM GABUNGAN
INDONESIA DENGAN MENGGUNAKAN METODE
ARTIFICIAL NEURAL NETWORK ALGORITMA
BACKPROPAGATION**

Nama Mahasiswa : Aldo Chandra Purnomo
NRP : 0521144000028
Jurusan : Sistem Informasi FTIK-ITS
Pembimbing I : Edwin Riksakomara, S.Kom, MT

ABSTRAK

Nilai Indeks Harga Saham Gabungan merupakan sebuah indeks pasar saham yang digunakan oleh Bursa Efek Indonesia (BEI). Nilai indeks harga saham gabungan merepresentasikan pergerakan seluruh harga saham yang tercatat di BEI. Kegunaan dalam penghitungan indeks harga saham gabungan adalah dapat digunakan sebagai patokan bagi pemerintah untuk mengambil kebijakan dibidang ekonomi. Biasanya indeks harga saham gabungan digunakan sebagai patokan dalam perhitungan pertumbuhan ekonomi sebuah negara dalam bentuk persentase. Setiap transaksi tercatat dengan skala waktu yang kecil, sehingga menyebabkan perubahan yang terjadi pada nilai IHSG sangat cepat dan tidak pasti.

Indeks harga saham gabungan sendiri memiliki berbagai ketidakpastian yang dapat mempengaruhi nilai dari indeks harga saham Indonesia. Ketidakpastian tersebut mencakup kondisi internal dan eksternal negara yang dapat meningkatkan atau menurunkan nilai harga saham perusahaan – perusahaan kapitalis yang nantinya akan menurunkan nilai indeks harga saham Indonesia.

Salah satu metode dalam peramalan yang populer untuk dapat meramalkan indeks harga saham gabungan Indonesia sendiri

adalah dengan menggunakan metode Artificial Neural Network. Sebelum melakukan peramalan, perlu dilakukan pembuatan model yang paling sesuai dengan parameter-parameter yang tersedia sehingga memiliki nilai error yang paling rendah. Model inilah yang akan digunakan untuk melakukan peramalan pada periode selanjutnya dalam pemodelan Artificial Neural Network.

Tugas akhir ini memberikan model peramalan indeks harga saham gabungan dengan menggunakan Artificial Neural Network dengan algoritma Backpropagation. Adapun hasil nilai peramalan indeks harga saham gabungan yang didapatkan memiliki model terbaik (16,16,1) dengan nilai MSE 1818.93 dan MAPE 0.613%. Harapannya model terbaik yang dihasilkan dari penelitian ini dapat digunakan untuk membantu pemerintah dalam pembuatan kebijakan yang dapat meningkatkan perekonomian negara di masa yang akan datang.

Kata Kunci: *Artificial Neural Network, Model, IHSG, Peramalan*

**FORECASTING INDONESIAN COMPOSITE INDEX
WITH ARTIFICIAL NEURAL NETWORK
BACKPROPAGATION ALGORITHM**

Student Name : Aldo Chandra Purnomo
Student ID : 0521144000028
Department : Information System FTIK-ITS
Supervisor I : Edwin Riksakomara, S.Kom, MT

ABSTRACT

Indonesian Composite Index Index is a stock market index used by the Indonesia Stock Exchange (IDX). The value of the composite share price index represents the movement of all stock prices listed on the Stock Exchange. Usefulness in calculating the composite stock price index can be used as a benchmark for the government to take policy in the field of economy. Usually the composite stock price index is used as a benchmark in calculating a country's economic growth in percentage form. Each transaction is recorded with a small time scale, resulting in changes that occur in the JCI index is very fast and uncertain.

The composite share price index itself has various uncertainties that could affect the value of Indonesia stock price index. These uncertainties include the internal and external conditions of the state that can increase or decrease the value of stock prices of capitalist companies that will later lower the Indonesian stock price index.

One of the motives in popular forecasting to predict the composite share price index of Indonesia itself is by using Artificial Neural Network method. Before doing the forecasting,

it is necessary to make the model that best suits the parameters available so that it has the lowest error value. This model will be used to forecast the next period in Artificial Neural Network modeling.

This final project provides forecasting model of composite stock price index by using Artificial Neural Network with Backpropagation algorithm. The results of forecasting value of the composite stock price index obtained has the best model (16,16,1) with MSE 1818.93 and MAPE 0.613%. The hope of the best model generated from this research can be used to assist the government in policy making that can boost the economy of the country in the future.

Keywords : Artificial Neural Network, Model, Indonesian Composite Index, Forecasting

KATA PENGANTAR

Puji syukur kehadirat Tuhan Yang Maha Kuasa, karena hanya dengan kasih-Nya penulis dapat diberikan kelancaran dalam menyelesaikan tugas akhir dengan judul :

PERAMALAN INDEKS HARGA SAHAM GABUNGAN INDONESIA DENGAN MENGGUNAKAN METODE *ARTIFICIAL NEURAL NETWORK* ALGORITMA *BACKPROPAGATION*

Terima kasih kepada pihak-pihak yang telah mendukung, memberikan saran, motivasi, semangat, bantuan dan doa demi tercapainya tujuan pembuatan tugas akhir ini. Secara khusus penulis akan menyampaikan ucapan terima kasih yang sebesar-besarnya kepada :

1. Bapak Dr. Ir. Aris Tjahyanto, M.Kom selaku Ketua Departemen Sistem Informasi ITS Surabaya.
2. Bapak Edwin Riksakomara, S.Kom, MT selaku dosen pembimbing yang meluangkan waktu untuk memberikan arahan, motivasi, dan membagikan ilmu untuk menyelesaikan tugas akhir ini.
3. Ibu Wiwik Anggraeni, S.SI, M.Kom dan Bapak Faizal Mahananto, S.Kom, M.Eng selaku dosen penguji yang telah memberikan saran dan masukan untuk perbaikan tugas akhir ini.
4. Orang tua penulis, Kris Aji Purnomo dan Purwatiningsih yang selalu mendukung dan mendoakan penulis agar dapat segera menyelesaikan tugas akhir ini.
5. Adik kandung penulis, Riska Deviana Novitasari yang selalu mendukung penulis.
6. Seluruh dosen Departemen Sistem Informasi yang telah memberikan ilmu yang sangat bermanfaat bagi penulis.

7. Maria Elizabeth Kusuma yang telah mendukung, mendoakan, dan membantu dalam menyelesaikan penulisan tugas akhir ini.
8. Wisnu, Bimo, Joel, Mahut dan Sondra yang telah menemani penulis dalam mengerjakan tugas – tugas selama menjalani perkuliahan.
9. Adik – adik bimbing 2016 dan 2017 yang memberikan support, doa dan motivasi kepada penulis untuk menyelesaikan perkuliahan tepat waktu.
10. Teman – teman angkatan OSIRIS yang telah berjuang bersama dalam menjalani perkuliahan di Departemen Sistem Informasi ITS.
11. Berbagai pihak yang membantu dalam penyusunan Tugas Akhir ini dan belum dapat disebutkan satu per satu dengan dukungan, semangat dan kebersamaan.

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

Surabaya, Juli 2018
Penulis,

(Aldo Chandra Purnomo)

DAFTAR ISI

LEMBAR PENGESAHAN....	Error! Bookmark not defined.
LEMBAR PERSETUJUAN...	Error! Bookmark not defined.
KATA PENGANTAR	xv
DAFTAR ISI.....	xvii
DAFTAR GAMBAR	xxi
DAFTAR TABEL.....	xxiii
DAFTAR SCRIPT	xxv
BAB I.....	1
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah.....	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
1.6 Relevansi Tugas Akhir	5
1.7 Sistematika Penulisan	6
BAB II.....	7
TINJAUAN PUSTAKA.....	7
2.1 Penelitian Sebelumnya	7
2.2 Dasar Teori.....	13
2.2.1 Indeks Harga Saham Gabungan.....	13
2.2.2 Peramalan	14
2.2.3 <i>Time Series</i>	14
2.2.4 <i>Artificial Neural Network</i>	16
2.2.5 Fungsi Aktivasi.....	16
2.2.6 Metode Backpropagation.....	19
2.2.7 Algoritma Backpropagation.....	21
2.2.8 Evaluasi Peramalan.....	25
BAB III	27
METODOLOGI.....	27
3.1 Tahapan Pelaksanaan.....	27
3.2 Uraian Metodologi	28
3.2.1 Inisiasi Penelitian.....	28

3.2.2	Pengolahan Data.....	28
3.2.3	Pengembangan Model	29
3.2.4	Training dan Testing Pada Model.....	30
3.2.5	Analisa Hasil	30
3.2.6	Penyusunan Laporan Akhir	30
BAB IV	31
PERANCANGAN	31
4.1	Pengumpulan Data.....	31
4.2	Pengolahan Data.....	32
4.3	Penetapan Variabel.....	33
4.4	Perancangan Model ANN.....	38
4.4.1	Pembagian Data.....	38
4.4.2	Model Neural Network	38
4.4.3	Penentuan <i>Input layer</i>	38
4.4.3	Penentuan <i>Hidden layer</i>	38
4.4.4	Penentuan Parameter	39
BAB V	43
IMPLEMENTASI	43
5.1	Pembagian Data.....	43
5.2	Pembuatan Model Artificial Neural Network	44
5.2.1	Model Artificial Neural Network.....	44
5.2.2	Data Input	46
5.2.3	Data Output	46
5.2.4	Parameter Model.....	46
5.3	Penerapan Model Artificial Neural Network	46
5.3.1	Deskripsi Parameter.....	47
5.3.2	Fungsi Perulangan	48
5.3.3	Pembuatan Struktur Neural Network	49
5.3.4	Proses Training dan Testing	51
5.3.5	Penyimpanan Model Matlab	52
5.3.6	Penyimpanan Hasil Training dan Testing	53
5.3.7	Fungsi MSE.....	54
5.3.8	Fungsi Penutup	55
BAB VI	57
ANALISIS HASIL DAN PEMBAHASAN	57

6.1	Lingkungan Uji Coba	57
6.2	Percobaan Parameter	58
6.3	Percobaan Model	58
6.3.1	Model Node Input 2	59
6.3.2	Model Node Input 4	61
6.3.3	Model Node Input 6	63
6.3.4	Model Node Input 8	65
6.3.5	Model Node Input 10	67
6.3.6	Model Node Input 12	69
6.3.7	Model Node Input 14	71
6.3.8	Model Node Input 16	73
6.3.9	Model Node Input 18	75
6.3.10	Model Node Input 20	78
6.4	Kesimpulan Hasil Percobaan	80
6.5	Perbandingan Hasil Percobaan	83
6.6	Hasil Peramalan	86
BAB VII		89
KESIMPULAN DAN SARAN		89
7.1	Kesimpulan	89
7.2	Saran	90
DAFTAR PUSTAKA		91
BIODATA PENULIS		93
LAMPIRAN		

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 2.1 Rumus IHSG	13
Gambar 2.2 Rata - Rata IHSG	14
Gambar 2.3 Step Function Binnary	17
Gambar 2.4 Signum Function Binnary	17
Gambar 2.5 Sigmoid Function Binnary	18
Gambar 2.6 Hyperbolic Tangent Binnary	18
Gambar 2.7 Linear Deriative Binnary	19
Gambar 2.8 Arsitektur Backpropagation	20
Gambar 3.1 Metodologi Penelitian.....	27
Gambar 4.1 Data Close price yang Didapatkan.....	31
Gambar 4.2 Data Kurs Jual yang Didapatkan.....	32
Gambar 4.3 Data Close price dan Kurs Jual	33
Gambar 5.1 Data Training.....	43
Gambar 5.2 Data Testing	44
Gambar 5.3 Model Artificial Neural Network.....	45
Gambar 6.1 Parameter Epoch.....	58
Gambar 6.2 Perbandingan MSE Node Input 2	60
Gambar 6.3 Plot Data Node Input 2	61
Gambar 6.4 Perbandingan MSE Node Input 4	62
Gambar 6.5 Plot Data Node Input 4	63
Gambar 6.6 Perbandingan MSE Node Input 6	64
Gambar 6.7 Plot Data Node Input 6	65
Gambar 6.8 Perbandingan MSE Node Input 8	66
Gambar 6.9 Plot Data Node Input 8	67
Gambar 6.10 Perbandingan MSE Node Input 10	68
Gambar 6.11 Plot Data Node Input 10	69
Gambar 6.12 Perbandingan MSE Node Input 12	70
Gambar 6.13 Plot Data Node Input 12	71
Gambar 6.14 Perbandingan MSE Node Input 14	72
Gambar 6.15 Plot Data Node Input 14	73
Gambar 6.16 Perbandingan MSE Node Input 16	74
Gambar 6.17 Plot Data Node Input 16	75
Gambar 6.18 Perbandingan MSE Node Input 18	77

Gambar 6.19 Plot Data Node Input 18	77
Gambar 6.20 Perbandingan MSE Node Input 20	79
Gambar 6.21 Plot Data Node Input 20	80
Gambar 6.22 Perbandingan MSE Node Input	81
Gambar 6.23 Model ANN Terbaik	82
Gambar 6.24 Grafik Data Perbandingan.....	83
Gambar 6.25 Perbandingan MSE A dan B	84
Gambar 6.26 Hasil Plotting Model B Terbaik	85
Gambar 6.27 Plot Data Aktual dan Hasil Peramalan	87

DAFTAR TABEL

Tabel 2.1 Penelitian Sebelumnya	7
Tabel 4.1 Variabel Input.....	33
Tabel 4.2 Data Input 1 Periode.....	34
Tabel 4.3 Variabel Input 1 Periode.....	34
Tabel 4.4 Data Input 2 Periode.....	35
Tabel 4.5 Variabel Input 2 Periode.....	35
Tabel 4.6 Data Input 3 Periode.....	35
Tabel 4.7 Variabel Input 3 Periode.....	36
Tabel 4.8 Data Input 4 Periode.....	36
Tabel 4.9 Variabel Input 4 Periode.....	36
Tabel 4.10 Data Input 5 Periode.....	37
Tabel 4.11 Variabel Input 5 Periode.....	37
Tabel 4.12 Rancangan Struktur Model ANN	41
Tabel 5.1 Penjelasan Script Parameter	47
Tabel 5.2 Penjelasan Script Perulangan.....	48
Tabel 5.3 Penjelasan Script Pembuatan Neural Network	49
Tabel 5.4 Penjelasan Script Training dan Testing	51
Tabel 5.5 Penjelasan Script Penyimpanan Model.....	52
Tabel 5.6 Penjelasan Script Save Hasil	53
Tabel 5.7 Penjelasan Script Uji Performa MSE.....	54
Tabel 5.7 Penjelasan Script Penutup	55
Tabel 6.1 Lingkungan Perangkat Keras.....	57
Tabel 6.2 Lingkungan Perangkat Lunak.....	57
Tabel 6.3 Jumlah Model Tiap Node	59
Tabel 6.4 Hasil Model 2 Node Input	60
Tabel 6.5 Hasil Model 4 Node Input	61
Tabel 6.6 Hasil Model 6 Node Input	63
Tabel 6.7 Hasil Model 8 Node Input	65
Tabel 6.8 Hasil Model 10 Node Input	67
Tabel 6.9 Hasil Model 12 Node Input	69
Tabel 6.9 Hasil Model 14 Node Input	71
Tabel 6.10 Hasil Model 16 Node Input	73
Tabel 6.11 Hasil Model 18 Node Input	76

Tabel 6.12 Hasil Model 20 Node Input	78
Tabel 6.13 Kesimpulan Hasil Model	80
Tabel 6.14 MSE Model	84
Tabel 6.15 Hasil Peramalan.....	86

DAFTAR SCRIPT

Script 5.1 Deskripsi Parameter	47
Script 5.2 Fungsi Perulangan.....	48
Script 5.3 Pembuatan Neural Network	49
Script 5.4 Proses Training dan Testing.....	51
Script 5.5 Proses Training dan Testing.....	52
Script 5.6 Penyimpanan Hasil Training dan Testing	53
Script 5.7 Penghitungan MSE	54
Script 5.8 Fungsi Penutup	55

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

Pada bab pendahuluan akan diuraikan proses identifikasi masalah penelitian yang meliputi latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, manfaat kegiatan tugas akhir dan relevansinya terhadap pengerjaan tugas akhir. Berdasarkan uraian pada bab ini, harapannya gambaran umum permasalahan dan pemecahan masalah pada tugas akhir dapat dipahami.

1.1 Latar Belakang

Indeks harga saham gabungan merupakan salah satu indeks pasar saham yang digunakan oleh Bursa Efek Indonesia dan dipergunakan untuk melihat perkembangan harga saham dari waktu ke waktu atau dari sejak indeks harga saham gabungan tersebut dihitung. Nilai indeks harga saham gabungan merepresentasikan pergerakan seluruh harga saham yang tercatat di BEI. Kegunaan dihitungnya indeks harga saham gabungan adalah dapat digunakan sebagai patokan bagi pemerintah untuk mengambil kebijakan dibidang ekonomi. Biasanya indeks harga saham gabungan digunakan sebagai patokan dalam perhitungan pertumbuhan ekonomi sebuah negara dalam bentuk persentase. Indeks harga saham gabungan juga merupakan *leading indicator economic*. [1]

Adapun indikator ekonomi yang dipergunakan para ahli yaitu inflasi, tingkat bunga, jumlah pengangguran, indeks harga saham, jumlah uang beredar, indeks perdagangan besar, indeks nilai tukar mata uang, ekspor, impor dan pertumbuhan ekonomi serta kredit yang disalurkan. Dari semua indikator ekonomi tersebut indeks harga saham gabungan dianggap menjadi pemimpin atau yang lebih dulu menceritakan keadaan di masa mendatang.

Adanya kemungkinan pertumbuhan ekonomi di masa mendatang, akan menyebabkan peningkatan pendapatan pada perusahaan. Adanya ekspektasi akan peningkatan pendapatan perusahaan direfleksikan pada harga saham. Harga saham yang mengalami kenaikan akan ditunjukkan dengan peningkatan indeks harga saham gabungan di mana kejadian pertumbuhan ekonomi tersebut belum terjadi. Karena itu, pertumbuhan indeks harga saham gabungan dipergunakan berbagai pihak untuk melihat situasi ke depan.

Pada era modern ini, terdapat beberapa metode yang berbeda dalam hal memprediksi harga saham. Metode yang paling umum adalah metode machine learning. Metode machine learning, menggunakan sampel harga saham dan mencoba melihat pola-pola yang terbentuk dari pergerakan harga saham tersebut menggunakan suatu algoritma yang dapat mempelajari pola. Ada banyak jenis metode yang termasuk dalam machine learning, misalnya *genetic algorithms*, *fuzzy logic*, *intelligent system*, dan *artificial neural network* (ANN). Dari bermacam-macam metode machine learning tersebut, metode terbaik yang dapat dipakai untuk menghadapi ketidakpastian indeks harga saham adalah metode Artificial Neural Network (ANN). Model ANN menganalisa data yang diperlukan dalam menentukan asumsi – asumsi dalam membuat *heuristic forecasting*. Pada beberapa studi, metode ANN sudah terbukti menjadi alat yang efektif dalam melakukan proses peramalan, dan menjadi acuan dalam melakukan prediksi dengan menggunakan data yang memiliki banyak variabel dan tanpa pattern. [2]

Pemodelan ANN dilakukan pada data yang berupa time series. Data time series adalah nilai-nilai suatu variabel yang berurutan menurut waktu, yaitu harian, bulanan, atau tahunan. Data yang didapatkan akan digunakan untuk membuat model time series. Model time series adalah suatu peramalan nilai-nilai masa depan yang didasarkan pada nilai-nilai masa lalu suatu variabel dan atau kesalahan di masa lalu.

Observasi dilakukan pada data hari kerja harian indeks harga saham gabungan dan nilai tukar IDR - USD selama 10 tahun, mulai dari tanggal 2 Januari 2008 hingga tanggal 2

Januari 2018. Sebelum melakukan peramalan, perlu dilakukan pembuatan model yang paling sesuai dengan parameter-parameter yang tersedia sehingga memiliki nilai MSE dan MAPE yang paling rendah. Model inilah yang akan digunakan untuk melakukan peramalan pada periode selanjutnya dalam pemodelan Artificial Neural Network.

Tugas akhir ini memberikan model peramalan indeks harga saham gabungan dengan menggunakan Artificial Neural Network dengan algoritma Backpropagation. Adapun hasil nilai peramalan indeks harga saham gabungan yang dihasilkan dari penelitian ini harapannya dapat membantu pemerintah dalam pembuatan kebijakan dalam bidang ekonomi untuk meningkatkan perekonomian negara di masa yang akan datang.

1.2 Perumusan Masalah

Permasalahan dalam penelitian ini yang berusaha untuk dijawab adalah sebagai berikut:

1. Bagaimana membangun model yang cocok untuk digunakan dalam peramalan indeks harga saham gabungan.
2. Berapa tingkat akurasi peramalan indeks harga saham gabungan dengan menggunakan metode Artificial Neural Network Backpropagation

1.3 Batasan Masalah

Batasan-batasan yang digunakan dalam pembahasan karya akhir ini meliputi sampel / obyek pengamatan, dan periode pengamatan sebagai berikut:

1. Penelitian dilakukan pada studi kasus Indeks Harga Saham Gabungan Indonesia.
2. Variabel input yang digunakan adalah data historis *closed price* indeks harga saham gabungan yang diperoleh dari website *yahoo.finance* [3] dan kurs USD – IDR yang diperoleh dari Bank Indonesia.[4]

3. Harga indeks saham yang diramalkan adalah *closed price* indeks harga saham gabungan Indonesia periode selanjutnya.
4. Periode pengamatan adalah indeks harga saham harian 10 tahun terakhir (2 Januari 2008 sampai dengan 2 Januari 2018).
5. Observasi dilakukan pada hari kerja dan tidak termasuk hari Sabtu, Minggu, dan hari libur nasional.
6. Software peramalan yang digunakan adalah Matlab.

1.4 Tujuan Penelitian

Berdasarkan perumusan masalah yang disebutkan sebelumnya, tujuan yang akan dicapai melalui tugas akhir ini adalah:

1. Mengetahui model yang sesuai dalam melakukan peramalan menggunakan ANN dalam meramalkan indeks harga saham gabungan.
2. Mengetahui tingkat keakuratan proses peramalan harga saham di Indonesia jika menggunakan pendekatan ANN.

1.5 Manfaat Penelitian

Melalui tugas akhir ini diharapkan dapat memberi manfaat yaitu:

Bagi akademis

1. Memberikan kontribusi pengetahuan mengenai penerapan metode peramalan untuk membantu memprediksi indeks harga saham gabungan Indonesia.
2. Menambah referensi dalam perumusan implementasi metode peramalan, khususnya dengan menggunakan metode *Artificial Neural Network Backpropagation* sehingga dapat dijadikan sebagai acuan untuk penelitian selanjutnya.

Bagi masyarakat umum

1. Memberikan gambaran bagi masyarakat umum untuk dapat mengetahui dan memantau pertumbuhan ekonomi di Indonesia dengan melihat indeks harga saham gabungan periode selanjutnya.
2. Memberikan gambaran bagi investor untuk melihat peluang melakukan investasi pada perusahaan kapital di Indonesia dengan resiko yang lebih sedikit.
3. Pengembangan lebih lanjut dari penelitian ini dapat digunakan para ahli ekonomi untuk mengantisipasi krisis ekonomi yang mungkin terjadi di masa mendatang.

1.6 Relevansi Tugas Akhir

Usulan Tugas Akhir yang diajukan akan memanfaatkan ilmu pengetahuan mengenai peramalan dan pengolahan data, yang diajarkan dalam mata kuliah Teknik Peramalan. Sehingga dapat disimpulkan bahwa Usulan Tugas Akhir yang diajukan sesuai dengan ranah penelitian Sistem Informasi. Selain relevansi dengan ranah penelitian Sistem Informasi secara umum, perlu dibuktikan adanya relevansi antara penelitian yang akan dilakukan dengan ranah penelitian yang ada pada laboratorium Rekayasa Data dan Intelegensi Bisnis (RDIB), yang terletak pada Jurusan Sistem Informasi Institut Teknologi Sepuluh Nopember Surabaya. Mata kuliah Teknik Peramalan dan topik Penggalian Data terdapat dalam lab RDIB. Sehingga dapat disimpulkan bahwa Topik Tugas Akhir yang diajukan merupakan topik untuk laboratorium RDIB.

1.7 Sistematika Penulisan

Adapun penulisan penelitian ini dibagi atas lima bab, yaitu

a. Bab I Pendahuluan

Dalam bab ini dijelaskan mengenai latar belakang masalah, rumusan masalah, batasan masalah, tujuan penelitian dan sistematika penulisan.

b. Bab II Tinjauan Pustaka

Dijelaskan mengenai penelitian-penelitian sebelumnya yang serupa serta teori-teori serta definisi yang menjadi dasar perhitungan untuk mengkaji bab pembahasan.

c. Bab III Metodologi

Dalam bab ini dijelaskan mengenai tahapan – tahapan apa saja yang harus dilakukan dalam pengerjaan tugas akhir.

d. Bab IV Perancangan

Bab ini berisi tentang bagaimana rancangan yang akan digunakan untuk implementasi metode yang digunakan.

e. Bab V Implementasi

Bab yang berisi tentang setiap langkah yang dilakukan dalam implementasi metodologi yang digunakan dalam tugas akhir.

f. Bab VI Analisis Hasil dan Pembahasan

Bab yang berisi tentang analisis dan pembahasan dalam penyelesaian permasalahan yang dibahas pada pengerjaan tugas akhir.

g. Bab VI Kesimpulan dan Saran

Bab ini berisi kesimpulan dari hasil penelitian dan saran untuk penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

Bab ini akan menjelaskan mengenai penelitian sebelumnya dan dasar teori yang dijadikan acuan atau landasan dalam pengerjaan tugas akhir ini. Landasan teori akan memberikan gambaran secara umum dari landasan penjabaran tugas akhir ini.

2.1 Penelitian Sebelumnya

Dalam penyusunan Tugas Akhir, terdapat beberapa penelitian terkait yang sebelumnya telah dilakukan oleh pihak lain. Adapun hasil – hasil penelitian tersebut akan dijadikan sebagai referensi dalam penyusunan Tugas Akhir. Deskripsi singkat dari penelitian yang telah dilakukan termuat pada Tabel 1 .

Tabel 2.1 Penelitian Sebelumnya

Penelitian 1	
Judul Penelitian	Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market [5]
Penulis	Mingyue Qiu, Yu Song, Fumio Akagi
Tahun	2016

Deskripsi Penelitian	<p>Penelitian ini membahas mengenai peramalan dari indeks harga saham gabungan Jepang (<i>Nikkei</i>) menggunakan metode <i>Artificial Neural Network</i> algoritma <i>Backpropagation</i>. Penelitian ini diawali dengan melakukan pemilihan variabel yang dapat mempengaruhi <i>Nikkei</i> dengan metode <i>Fuzzy</i>. Variabel yang didapatkan berjumlah 71 variabel data dengan berbagai aspek. Setelah dilakukan idektifikasi variabel yang mempengaruhi, ditemukan 18 variabel yang benar –benar mempengaruhi <i>Nikkei</i>. Hasil akhir dari penelitian ini menghasilkan nilai MSE 0.044 yang dapat dikategorikan sangat bagus.</p>
Relevansi	<p>Penelitian yang dilakukan sama-sama menggunakan metode <i>Artificial Neural Network</i> algoritma <i>Backpropagation</i> untuk melakukan peramalan terhadap data yang ada. Namun variabel yang diramalkan pada penelitian ini berfokus pada data indeks harga saham gabungan Jepang (<i>Nikkei</i>). Objek yang diambil dalam Tugas Akhir ini mencoba menerapkan metode metode <i>Artificial Neural Network</i> algoritma <i>Backpropagation</i> dengan menggunakan data indeks harga saham gabungan Indonesia (IDX) dan variabel nilai tukar kurs IDR – USD.</p>

Penelitian 2	
Judul Penelitian	Impact of Foreign Exchange rate on stock prices[6]
Penulis	Maheen Jamil , Naeem Ullah
Tahun	2013
Deskripsi Penelitian	<p>Penelitian ini ingin membuktikan teori mengenai pengaruh antara nilai tukar mata uang dengan <i>stock market return</i> dan fluktuasi yang ada pada nilai saham. Penelitian dilakukan menggunakan <i>Root Test Phillip Perron</i> untuk membuat hipotesis keterkaitan antara perubahan nilai tukar mata uang, dengan <i>Market Return</i> dari pasar saham. Selanjutnya dilakukan analisa menggunakan metode VECM untuk menentukan apakah relasi antara kedua variabel tersebut memiliki efek jangka panjang atau jangka pendek. Penelitian menunjukkan bahwa terdapat relasi antara kedua variabel tersebut, dimana ketika terdapat fluktuasi pada nilai tukar mata uang, akan terdapat fluktuasi juga pada <i>market return</i>, dan ketika nilai tukar stagnan, <i>market return</i> juga stagnan.</p>

Relevansi	Penelitian yang dilakukan membuktikan bahwa terdapat keterkaitan antara nilai tukar mata uang terhadap mata uang asing dengan nilai saham. Sehingga menunjang penggunaan variabel nilai tukar IDR – USD untuk meramalkan nilai indeks harga saham gabungan.
Penelitian 3	
Judul Penelitian	Forecasting stock indices with back propagation neural network [7]
Penulis	J.-Z. Wang, J.-J. Wang, Z.-G. Zhang
Tahun	2011
Deskripsi Penelitian	Penelitian ini membahas mengenai peramalan dari indeks harga saham gabungan Shanghai, dengan data <i>closing price</i> bulanan, menggunakan metode <i>Artificial Neural Network</i> algoritma <i>Backpropagation</i> . Penelitian ini menggunakan satu variabel untuk meramalkan asil akhir dari penelitian dengan periode data bulanan, pada hasil akhir penelitian, didapatkan nilai MAPE sebesar 0.4364 yang berarti hasil akhir dari penelitian ini sangat baik dan dapat diimplementasikan..

Relevansi	<p>Penelitian menunjukkan bahwa indeks harga saham gabungan dapat diramalkan dengan menggunakan metode backpropagation. Pada penelitian ini menggunakan data bulanan, dan menggunakan variabel input, sehingga akan dilakukan percobaan lain pada penelitian ini dengan menggunakan beberapa variabel input, dan menggunakan rentang data yang lebih luas, yaitu data harian. Penelitian sama – sama menggunakan metode <i>Artificial Neural Network Backpropagation</i>, namun pada penelitian Tugas Akhir tidak hanya menggunakan satu variabel untuk peramalan, namun menggunakan beberapa variabel penunjang lainnya.</p>
Penelitian 4	
Judul Penelitian	<p>Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index – Case study of PETR4, Petrobras, Brazil [8]</p>
Penulis	De Oliveira F, Nobre C, Zárate L
Tahun	2013

Deskripsi Penelitian	<p>Penelitian ini membahas mengenai peramalan dari harga saham PETR4 Brazil menggunakan metode <i>Artificial Neural Network</i> algoritma <i>Backpropagation</i>. Penelitian ini mencoba meramalkan harga saham PETR4 dengan variabel – variabel yang berkaitan dengan aspek – aspek yang dapat mempengaruhi harga saham PETR4 untuk membuat model yang sesuai dalam melakukan peramalan harga saham PETR4. Variabel yang terkait adalah harga opening price, closing price, maximum price, minimum price dari harga saham PETR4. Variabel lain yaitu pendapatan karyawan perusahaan, harga minyak, penjualan produk pada retail, IPCA, dan lain – lain. Hasil akhir dari penelitian ini menghasilkan nilai MAPE 5,45 %, dan termasuk hasil yang sangat baik jika dilihat dari tingkat error yang rendah.</p>
Relevansi	<p>Penelitian menunjukkan bahwa variabel opening price, closing price, maximum price, dan minimum price dapat digunakan sebagai variabel yang menentukan hasil akhir peramalan harga saham. Sehingga dapat digunakan dalam proses pemodelan yang nantinya akan digunakan dalam proses peramalan menggunakan <i>Artificial Neural Network Backpropagation</i></p>

Sesuai dengan literature review yang telah dilakukan pada studi – studi sebelumnya, dapat disimpulkan bahwa variabel yang digunakan dalam proses peramalan indeks harga saham gabungan Indonesia dapat digunakan, dan memiliki keterkaitan dalam mempengaruhi hasil akhir peramalan.

2.2 Dasar Teori

Pada bagian ini akan dijelaskan mengenai teori-teori yang digunakan untuk mendukung penelitian tugas akhir ini.

2.2.1 Indeks Harga Saham Gabungan

Indeks Harga Saham Gabungan merupakan salah satu indeks pasar saham yang digunakan oleh Bursa Efek Indonesia. IHSG dapat dipergunakan untuk melihat perkembangan harga saham dari waktu ke waktu atau dari sejak IHSG tersebut dihitung.[9] Diperkenalkan pertama kali pada tanggal 1 April 1983, sebagai indikator pergerakan harga saham di BEI, Indeks ini mencakup pergerakan harga seluruh saham biasa dan saham preferen yang tercatat di BEI. Hari dasar untuk perhitungan IHSG adalah tanggal 10 Agustus 1982. Pada tanggal tersebut, Indeks ditetapkan dengan Nilai Dasar 100 dan saham tercatat pada saat itu berjumlah 13 saham. [10]

Dasar perhitungan IHSG adalah jumlah Nilai Pasar dari total saham yang tercatat pada tanggal 10 Agustus 1982. Jumlah Nilai Pasar adalah total perkalian setiap saham tercatat dengan harga di BEJ pada hari tersebut. Formula perhitungannya adalah sebagai berikut:

$$IHSG = \frac{\sum P}{d} \times 100$$

Gambar 2.1 Rumus IHSG

dimana p adalah harga penutupan Pasar Reguler, x adalah Jumlah Saham, dan d adalah Nilai Dasar.

$$\text{Rata - Rata IHS}G = \frac{\text{Jumlah IHS}G \text{ periode harian selama 1 bulan}}{\text{Jumlah periode waktu selama 1 bulan}}$$

Gambar 2.2 Rata - Rata IHS}G

Perhitungan Indeks merepresentasikan pergerakan harga saham di pasar/bursa yang terjadi melalui sistem perdagangan lelang. Nilai Dasar akan disesuaikan secara cepat bila terjadi perubahan modal emiten atau terdapat faktor lain yang tidak terkait dengan harga saham. Harga saham yang digunakan dalam menghitung IHS}G adalah harga saham di pasar reguler yang didasarkan pada harga yang terjadi berdasarkan sistem lelang.

2.2.2 Peramalan

Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien.[11] Peramalan adalah sebuah prediksi untuk melakukan perkiraan mengenai apa yang akan terjadi di masa yang akan datang. Peramalan dilakukan dengan memperkirakan suatu nilai variabel dengan memperhatikan nilai historis variabel tersebut untuk menentukan nilai variabel pada masa yang akan datang. Melakukan peramalan dapat dipengaruhi oleh keahlian judgment, yang selanjutnya dipengaruhi oleh data histori dan pengalaman. [12]

2.2.3 Time Series

. Data time series adalah nilai-nilai suatu variabel yang berurutan menurut waktu (misal: hari, minggu, bulan, tahun). Dalam data ekonomi biasanya kita mendapatkan adanya fluktuasi/ variasi dari waktu ke waktu atau disebut dengan variasi *time series*. [13] Variasi ini biasanya disebabkan oleh adanya faktor Trend (*trend factor*), Fluktuasi siklis (*cyclical fluktuation*), Variasi musiman (*seasonal variation*), dan pengaruh random (*irregular/random influences*).

a. **Trend**

Trend adalah keadaan data yang menaik atau menurun dari waktu ke waktu. Contoh yang menunjukkan trend menaik yaitu pendapatan per kapita dan jumlah penduduk.

b. **Variasi Musiman**

Variasi musiman adalah fluktuasi yang muncul secara reguler setiap tahun yang biasanya disebabkan oleh iklim, kebiasaan (mempunyai pola tetap dari waktu ke waktu). Contoh yang menunjukkan variasi musiman seperti penjualan pakaian akan meningkat pada saat hari raya, penjualan buku dan tas sekolah akan meningkat pada saat awal sekolah.

c. **Variasi Siklis**

Variasi siklis muncul ketika data dipengaruhi oleh fluktuasi ekonomi jangka panjang, variasi siklis ini bisa terulang setelah jangka waktu tertentu. Variasi siklis biasanya akan kembali normal setiap 10 atau 20 tahun sekali, bisa juga tidak terulang dalam jangka waktu yang sama. ini yang membedakan antara variasi siklis dengan musiman.

d. **Variasi Random**

Variasi random adalah suatu variasi atau gerakan yang tidak teratur (*irregular*). Variasi ini pada kenyataannya sulit diprediksi.

Model *Time Series* adalah suatu peramalan nilai-nilai masa depan yang didasarkan pada nilai-nilai masa lampau suatu variabel dan atau kesalahan masa lampau. Model *time series* biasanya lebih sering digunakan untuk suatu peramalan/prediksi.

2.2.4 Artificial Neural Network

Artificial Neural Network adalah sebuah system saraf selular fisik yang dapat memperoleh, menyimpan dan menggunakan pengetahuan yang telah di dapat dari pengalaman. [14] ANN merepresentasikan otak manusia buatan yang selalu melakukan proses pembelajaran pada otak manusia tersebut. dalam ANN terdapat 3 elemen yang berperan penting , yaitu sebagai berikut:

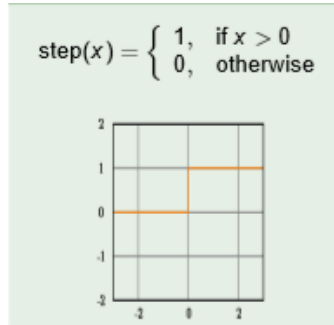
- a. Arsitektur jaringan beserta hubungan antar neuron
- b. Algoritma pembelajaran
- c. Fungsi aktivasi yang digunakan.

2.2.5 Fungsi Aktivasi

Fungsi aktivasi merupakan suatu fungsi yang akan mentransformasikan suatu inputan menjadi suatu output tertentu. Pada jaringan saraf tiruan suatu informasi akan diterima oleh inputan. Inputan ini akan diproses melalui suatu fungsi perambatan. Fungsi aktivasi pada jaringan backpropagation harus mempunyai beberapa karakteristik penting, berlanjut, dapat dibedakan, dan tidak meningkat secara monoton. Demi keefisienan komputasi, diharapkan turunan dari fungsi tersebut mudah untuk dikomputasikan. Fungsi diharapkan memenuhi pendekatan nilai maksimum dan nilai minimum. Fungsi-fungsi aktivasi yang umum digunakan adalah :

1. Step Function Binary


Function Binary mengkonversi unit input, di mana nilai variabelnya bersifat kontinu yang menghasilkan nilai output bernilai biner (yaitu 1 atau 0) atau bipolar (1 atau -1).



Gambar 2.3 Step Function Binnary

2. Signum Function Binary


Berfungsi mengkonversikan input dari suatu variabel yang bernilai kontinyu ke suatu output berupa nilai 1,0 atau -1.



Gambar 2.4 Signum Function Binnary

3. Sigmoid Function Binary


Fungsi ini digunakan untuk jaringan syaraf yang dilatih dengan menggunakan metode backpropagation. Fungsi sigmoid biner memiliki nilai pada range 0 sampai 1. Oleh karena itu, fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai output yang terletak pada interval 0 sampai 1.



Gambar 2.5 Sigmoid Function Binnary

4. Hyperbolic Tangent Binary


Fungsi ini akan membawa nilai input pada output dengan menggunakan rumus hyperbolic tangen sigmoid. Nilai maksimal output dari fungsi ini adalah 1 dan minimal -1.



Gambar 2.6 Hyperbolic Tangent Binnary

5. Linear Derivative Binary

Fungsi linear memiliki nilai output yang sama dengan nilai inputnya. $y = x$. Fungsi ini biasanya digunakan pada unit input untuk memberi nilai awal harga setiap unitnya.



Gambar 2.7 Linear Derivative Binnary

2.2.6 Metode Backpropagation

Backpropagation atau propogasi balik adalah sebuah metode Artificial Neural Network yang menggunakan algoritma Supervised Learning dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada *hidden layer* Artificial Neural Network Backpropagation terdiri dari beberapa lapisan, yaitu sebagai berikut :

1. *Input layer*

Input layer sebanyak 1 lapis yang terdiri dari neuron - neuron input, mulai dari neuron input pertama sampai neuron input ke-n. Dalam hal ini *input layer* akan merepresentasikan keadaan yang akan melakukan pelatihan pada jaringan.

2. *Hidden layer*

Hidden layer terdiri dari beberapa neuron tersembunyi mulai dari neuron tersembunyi awal sampai neuron tersembunyi ke-n. Pada *Hidden layer* terdapat beberapa aturan metode yang dapat digunakan untuk menentukan jumlah neuron yang akan digunakan pada *hidden layer*.

Jumlah neuron hidden layer berkisar antara $N + 1$ untuk multilayer perceptron neural network, dan bernilai sekitar $2N$ pada bridged multilayer perceptron neural netwok.[15]


Sehingga dapat disimpulkan bahwa jumlah hidden neuron n sampai dengan $2n$ sudah dapat menghasilkan hasil yang baik dalam jaringan, namun pada dasarnya jumlah hidden neuron yang digunakan dapat berjumlah sampai dengan tak berhingga. [16]

3. *Output layer*

Secara umum hampir sama dengan lapisan masukan dan tersembunyi, *output layer* berjumlah satu lapis yang terdiri dari neuron-neuron output mulai dari neuron output pertama sampai neuron output ke- n . Jumlah dari neuron output tergantung dari tipe dan performa dari jaringan saraf itu sendiri.

Pada metode *Artificial Neural Network Backpropagation*, terdapat 3 tahapan dalam proses pelatihannya, yaitu sebagai berikut:

1. Proses umpan maju (*Feedforward*) dari input
2. Perhitungan dan propogasi balik (*Backpropogation*) dari nilai error yang dihasilkan
3. Penyesuaian nilai bobot berdasarkan error output.



Gambar 2.8 *Arsitektur Backpropagation*

Algoritma Backpropagation akan menggunakan nilai error dari output untuk mengubah nilai bobot. Namun untuk mendapatkan nilai error ini, diharuskan mengerjakan terlebih dahulu proses umpan maju (*Feedforward*).

2.2.7 Algoritma Backpropagation

Algoritma backpropagation merupakan bagian dari algoritma pembelajaran terawasi yang biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot - bobot yang terhubung dengan neuron-neuron yang ada pada *hidden layer*. Algoritma ini menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*).

Adapun training backpropagation adalah dengan tahapan-tahapan sebagai berikut :

1. Langkah ke-0 : Inisialisasi bobot.
2. Langkah ke-1 : Selama kondisi berhenti bernilai salah, kerjakan langkah 2-9.
3. Langkah ke-2 : Untuk setiap data training, lakukan langkah 3-8.

Feedforward (Umpan Maju)

4. Setiap unit input ($i = 1, \dots, n$) menerima sinyal input x_i dan menyebarkan sinyal tersebut ke seluruh unit tersembunyi.
5. Pada setiap unit tersembunyi (X_j , $j = 1, \dots, p$), menjumlahkan sinyal-sinyal input yang sudah berbobot (termasuk biasanya)

$$X_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \dots \dots \dots (2.2.1)$$

Setelah itu menghitung sinyal output dari unit tersembunyi dengan menggunakan fungsi aktivasi yang telah ditentukan :

$$X_j = f(X_{in_j}) \dots \dots \dots (2.2.2)$$

Sinyal output ini selanjutnya dikirim ke seluruh unit pada unit atas (unit output).

6. Langkah ke-5 : Tiap-tiap unit output (Y_k , $k = 1, \dots, m$), menjumlahkan bobot sinyal input :

$$Y_{in_k} = w_{0k} + \sum_{i=1}^n x_i w_{ik} \dots \dots \dots (2.2.3)$$

Selanjutnya menghitung sinyal output dari unit output bersangkutan dengan menggunakan fungsi aktivasi yang telah ditentukan

$$Y_k = f(Y_{in_k}) \dots \dots \dots (2.2.4)$$

Backpropagation of Error (Propagasi Error)

7. Langkah ke-6 : Setiap unit output (Y_k , $k = 1, \dots, m$) menerima suatu pola target yang sesuai dengan pola input pelatihan, untuk menghitung kesalahan (error) antara target dengan output yang dihasilkan jaringan.

$$\delta_k = (t_k - y_k)(y_{in_k}) \dots \dots \dots (2.2.4)$$

Faktor δ_k digunakan untuk menghitung koreksi error (Δ) yang nantinya akan dipakai untuk memperbaiki w_{jk} , dimana :

$$\Delta w_{jk} = \alpha \delta_k \dots \dots \dots (2.2.5)$$

Faktor δ_k kemudian dikirimkan ke lapisan yang berada pada langkah ke-7.

8. Langkah ke-7 : Setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) menerima input delta (dari langkah ke-6) yang sudah berbobot

$$\delta_{in_j} = \sum_{k=1}^n \delta_k w_{jk} \dots \dots \dots (2.2.6)$$

Kemudian hasilnya dikalikan dengan turunan dari fungsi aktivasi yang digunakan jaringan untuk menghitung informasi kesalahan error , dimana :

$$\delta_j = \delta_{in_j} f'(Z_{in_j}) \dots \dots \dots (2.2.7)$$

Kemudian hitunglah koreksi bobot untuk memperbaiki v_{ij}

$$\Delta v_{ij} = \alpha \delta_j x_{i1} \dots \dots \dots (2.2.8)$$

Setelah itu hitung koreksi bias (digunakan untuk memperbaiki v_{0j})

$$\Delta v_{0j} = \alpha \delta_j \dots \dots \dots (2.2.9)$$

Adjustment

9. Langkah ke-8 : Setiap unit output ($Y_k, k = 1, \dots, m$) memperbaiki bobot dan bias dari setiap unit tersembunyi ($j = 0, \dots, p$)

$$w_{jk} \text{baru} = w_{jk} \text{lama} + \Delta w_{jk} \dots \dots \dots (2.2.10)$$

Rumus 2.11 Mencari bobot baru Demikian pula untuk setiap unit tersembunyi ($Z, j = 1, \dots, p$) akan

memperbaharui bobot dan bias dari setiap unit input ($i = 0, \dots, n$)

$$v_{ij}baru = v_{ij}lama + \Delta v_{ij} \dots \dots \dots (2.2.11)$$

10. Langkah ke-9 : Tes kondisi berhenti apabila error ditemukan . Jika kondisi stop telah terpenuhi, maka pelatihan jaringan dapat dihentikan.

Keterangan :

x_i ($i=1,2,\dots,n$)	: neuron <i>input layer</i>
x_i	: sinyal input
Z ($j=1,2,\dots,p$)	: neuron <i>hidden layer</i>
z_j	: sinyal <i>hidden layer</i>
Y_k ($k =1,2,\dots,m$)	: neuron <i>output layer</i>
y_k	: sinyal output
v_{0j}	: bias dari <i>input layer</i>
v_{ij}	: bobot dari <i>input layer</i>
w_{0k}	: bias dari <i>hidden layer</i>
w_{jk}	: bobot dari <i>hidden layer t</i>
t_k	: target output
δ_k	: informasi error <i>output layer</i>
δ_j	: informasi error <i>hidden layer</i>
α	: laju pembelajaran

2.2.8 Evaluasi Peramalan

Dalam pembuatan model dalam proses peramalan, perlu dilakukan proses evaluasi untuk mengetahui kinerja dari metode dan model peramalan yang telah dilakukan, dimana pengujian tersebut dilakukan untuk mengetahui error yang ada dalam model peramalan yang dibuat dengan dua pengukuran, yaitu sebagai berikut :

1. *Mean Square Error (MSE)*

Mean Square Error (MSE) mengukur ketepatan ramalan dengan merata-rata nilai kuadrat dari error yang dihasilkan. MSE merupakan salah satu cara untuk mengukur kesalahan peramalan keseluruhan untuk sebuah model. Rumus untuk menghitung MSE adalah sebagai berikut :

$$MSE = \frac{\sum(x_i - f_i)^2}{n} \dots\dots\dots (2.2.12)$$

MSE berarti rata – rata dari kuadrat error, dimana x_i adalah data aktual, f_i adalah nilai yang diramalkan , dan n adalah jumlah observasi.

2. *Mean Absolute Percentage Error (MAPE)*

Mean Absolute Percentage Error merupakan salah satu parameter yang sering digunakan dalam evaluasi peramalan. MAPE merepresentasikan nilai galat dari peramalan yang dilakukan dengan satuan persentase. Nilai MAPE diperoleh melalui perhitungan sebagai berikut:

$$MAPE = \sum \frac{|Aktual - Forecast|}{Aktual} \times 100\% \dots\dots\dots (2.2.13)$$

Dimana:

MAPE = Mean Absolute Percentage Error

N = Banyaknya periode di peramalan

Aktual = Data aktual

Forecast = Data hasil peramalan

Halaman ini sengaja dikosongkan

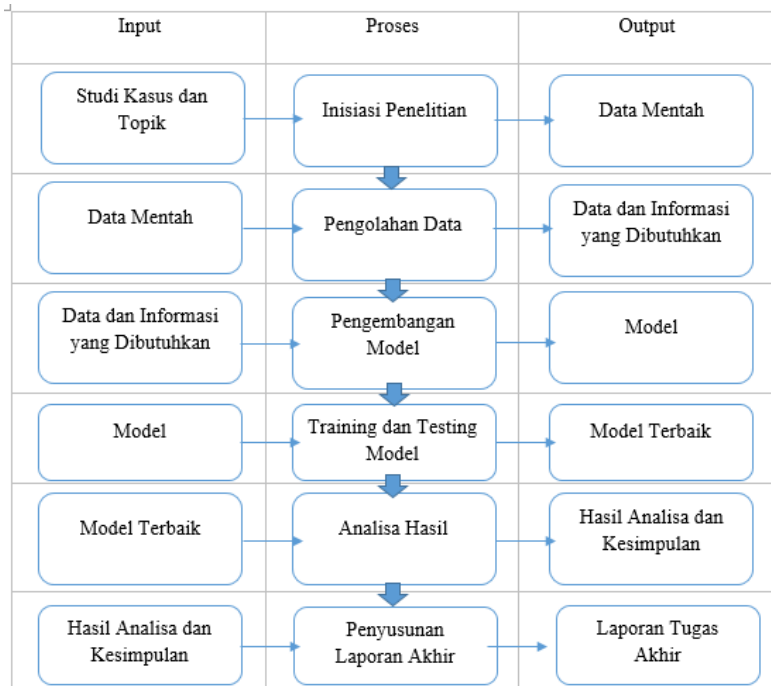
BAB III

METODOLOGI

Pada bab ini dijelaskan urutan langkah-langkah yang sistematis dalam pengerjaan tugas akhir ini sehingga dapat dijadikan sebagai pedoman agar pengerjaan dapat dilakukan dengan mudah, terorganisir dan sistematis.

3.1 Tahapan Pelaksanaan

Diagram alur dari urutan pelaksanaan Tugas Akhir akan dijabarkan dalam gambar 3.1 :



Gambar 3.1 Metodologi Penelitian

3.2 Uraian Metodologi

Pada bagian ini akan dijelaskan secara lebih rinci dari masing-masing tahapan yang terdapat pada diagram alur guna penyelesaian Tugas Akhir ini.

3.2.1 Inisiasi Penelitian

Pada tahap ini dilakukan identifikasi studi kasus, dan pencarian serta pengumpulan data yang dibutuhkan dalam studi kasus tersebut. Data yang dibutuhkan untuk penelitian Tugas Akhir ini adalah indeks harga saham gabungan dari tahun 2008 hingga tahun 2018 dengan periode harian yang bersumber dari website *yahoo.finance*. Setelah data diperoleh, maka selanjutnya dilakukan pengolahan terhadap data yang ada, dimana dilakukan pembersihan data dan pengisian data yang kosong, sehingga data siap digunakan.

3.2.2 Pengolahan Data

Tahap ini merupakan tahap lanjutan setelah inisiasi penelitian, dimana pada tahap ini dilakukan proses pengolahan data. Data yang dibutuhkan untuk penelitian Tugas Akhir ini adalah indeks harga saham gabungan dan kurs nilai tukar IDR – USD dari tahun 2008 hingga tahun 2018 dengan periode harian. Observasi dilakukan pada hari kerja, dan bersumber dari website Bank Indonesia dan *yahoo.finance*. Dilakukan pengolahan terhadap data yang ada, dilakukan pembersihan data bernilai null yang teridentifikasi sebagai hari libur nasional, dan pengisian data yang kosong dengan menggunakan data pada periode sebelumnya. Data observasi hari kerja nantinya akan dibandingkan dengan proses pengolahan data dengan mengasumsikan data hari Sabtu, Minggu dan hari libur nasional sama dengan data pada periode sebelumnya.

3.2.3 Pengembangan Model

Setelah tahap persiapan data selesai, maka selanjutnya merupakan tahap pengembangan model dimana pada tahap ini dilakukan perencanaan parameter yang akan digunakan untuk peramalan ANN dan pembuatan model dari ANN.

Parameter yang digunakan pada peramalan ini mencakup kombinasi *transfer function*, *training function*, momentum, *learning rate*, dan jumlah node *hidden layer*. Jumlah *hidden layer* berkisar antara n hingga $2n$, dimana n adalah jumlah node input. Node input dimulai dari 2 node, yaitu *close price* dan kurs jual pada satu periode sebelumnya, dan dilakukan percobaan hingga mendapatkan nilai MSE terbaik.

Persamaan dalam model ANN penelitian ini adalah sebagai berikut :

$$y(t) = f(d_{(t-1)}, e_{(t-1)}, d_{(t-2)}, e_{(t-2)} \dots \dots \dots d_{(t-n)}, e_{(t-n)})$$

Hidden layer = dimulai dari node n hingga $2n$ dari jumlah node input $(h_{(1)}, h_{(2)}, \dots \dots \dots, h_{(2n)})$

n = Jumlah periode yang digunakan untuk meramalkan satu periode kedepan.

$d_{(t-1)}$ = Data input *close price* pada 1 hari sebelumnya

$d_{(t-1)}$ = Data input kurs jual pada 1 hari sebelumnya

$d_{(t-2)}$ = Data input *close price* pada 2 hari sebelumnya

$d_{(t-2)}$ = Data input kurs jual pada 2 hari sebelumnya

$d_{(t-n)}$ = Data input *close price* pada n hari sebelumnya

$d_{(t-n)}$ = Data input kurs jual pada n hari sebelumnya

$h_{(1)}$ = 1 node pada *hidden layer*

$h_{(2)}$ = 2 node pada *hidden layer*

$h_{(2n)}$ = $2n$ node pada *hidden layer*

$y(t)$ = Data *close price* output

3.2.4 Training dan Testing Pada Model

Setelah parameter telah ditentukan dan model telah dibuat, maka selanjutnya merupakan tahap peramalan terhadap data yang telah disiapkan. Pembagian data sampel yang digunakan untuk peramalan adalah 75% untuk data training dan 25% untuk data testing sesuai dengan studi yang telah dilakukan sebelumnya. [17]

3.2.5 Analisa Hasil

Setelah hasil diperoleh dari peramalan terhadap data yang ada, maka dilakukan analisa hasil peramalan dan penarikan kesimpulan terhadap hasil peramalan yang ada. Kegiatan analisa dilakukan dengan membandingkan hasil peramalan dengan data aktual menggunakan parameter MSE. Setelah didapatkan analisa hasil peramalan menggunakan metode *Artificial Neural Network*, maka dilakukan perbandingan hasil yang didapatkan dengan data peramalan yang digunakan menggunakan model atau metode lainnya, sehingga dapat dilakukan analisa lebih lanjut mengenai hasil peramalan dengan metode *Artificial Neural Network*. Analisa juga dilakukan dengan membandingkan hasil yang didapatkan dengan proses pengolahan data observasi hari kerja dengan penggunaan seluruh data pada satu tahun. Setelah dilakukan kegiatan analisa hasil, maka selanjutnya dilakukan penarikan kesimpulan berdasarkan analisa hasil yang diperoleh, dengan mencari nilai MAPE untuk melihat presentase error dari model yang terbaik.

3.2.6 Penyusunan Laporan Akhir

Setelah semua tahap diatas dilakukan, maka tahap terakhir adalah melakukan dokumentasi hasil dari penelitian dengan melakukan penyusunan buku Tugas Akhir.


BAB IV

PERANCANGAN


Dalam bab perancangan ini akan dijelaskan mengenai perancangan model *Artificial Neural Network* yang digunakan untuk melakukan peramalan terhadap nilai *closed price* indeks harga saham gabungan Indonesia dan juga mengenai pengolahan data yang diperoleh dari situs *yahoo.finance* dan Bank Indonesia.

4.1 Pengumpulan Data

Observasi pada tugas akhir ini dilakukan pada data historis harian dari *closed price* indeks harga saham gabungan Indonesia dan nilai tukar kurs jual mata uang IDR - USD mulai dari 2 Januari tahun 2008 hingga 2 Januari tahun 2018. Observasi pada tugas akhir ini dilakukan pada hari kerja, dan data yang didapatkan akan digunakan sebagai sampel untuk melakukan peramalan *closed price* indeks harian harga saham gabungan Indonesia pada periode mendatang. Data nilai *closed price* indeks harga saham gabungan Indonesia dan nilai tukar kurs jual mata uang IDR - USD tahun 2008 hingga tahun 2018 didapatkan dari situs resmi keuangan *yahoo.finance* dan website Bank Indonesia (BI).



Gambar 4.1 Data Close price yang Didapatkan

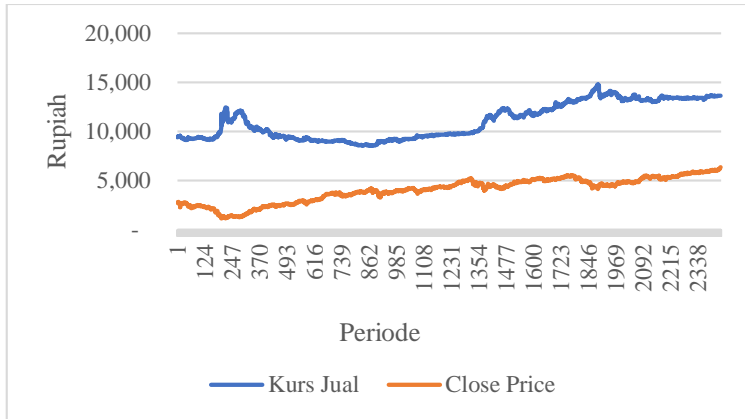


Gambar 4.2 Data Kurs Jual yang Didapatkan

Data histori yang didapatkan memiliki entri sebanyak 2464 untuk data closed price di Indonesia dan 2455 untuk nilai kurs jual IDR - USD, sehingga total data keseluruhan sebanyak 4919 entri. Data yang didapatkan berupa data mentah yang masih memiliki banyak data kosong. Data harus diolah terlebih dahulu untuk menghilangkan data kosong dan menyamakan jumlah entry data closed price dan nilai jual kurs IDR – USD.

4.2 Pengolahan Data

Pada tahap ini dilakukan proses pengolahan data mentah closed price dan nilai kurs jual IDR – USD sehingga memiliki jumlah entry yang sama dan tidak terdapat entry yang kosong. Observasi dilakukan pada hari kerja, sehingga dilakukan penghapusan entry yang terdeteksi sebagai hari sabtu, minggu, dan hari libur nasional. Untuk data hari kerja yang kosong diisi dengan data periode sebelumnya.



Gambar 4.3 Data Close price dan Kurs Jual

Sehingga didapatkan jumlah entry akhir closed price sebanyak 2441 data, dan nilai kurs jual IDR – USD sebanyak 2441 data. Sehingga didapatkan data entry keseluruhan sebanyak 4882 data.

4.3 Penetapan Variabel

Data antara *closed price* dan kurs nilai jual IDR - USD yang telah diolah dalam periode harian ditampilkan dalam tabel harian yang mencakup keseluruhan data. Keseluruhan data digabungkan menjadi sebuah tabel, dimana baris menunjukkan nilai variabel dalam periode harian. Sedangkan kolom menunjukkan jenis variabel, yaitu kurs jual dan *closed price*.

Tabel 4.1 Variabel Input

Tanggal	Close price (D)	Kurs Jual (E)
2-Jan-08	2731.50	9,417
3-Jan-08	2715.06	9,460
4-Jan-08	2765.18	9,471
7-Jan-08	2776.40	9,501
8-Jan-08	2785.62	9,502
...
2-Jan-18	6339.23	13,616

Setelah dilakukan pengolahan data, dilakukan penetapan variabel yang akan digunakan untuk melakukan peramalan. Variabel dibagi menjadi variabel input dan target output. Data historis *close price* dan kurs jual digunakan untuk meramalkan nilai *close price* periode yang akan datang. Peramalan dilakukan dengan *trial and error* untuk menentukan jumlah periode peramalan, dan ditentukan model dari periode tersebut yang memiliki MSE paling kecil. Variabel *Close price* disimbolkan sebagai D, dan kurs jual sebagai E. Target output digambarkan dengan variabel Y, sebagai nilai *close price* pada periode yang akan datang.

Rancangan Satu Periode :

Dilakukan peramalan dengan menggunakan satu periode variabel input untuk meramalkan satu periode kedepan.

Tabel 4.2 Data Input 1 Periode

D1	2 Januari 2008 - 29 Januari 2018
E1	2 Januari 2008 - 29 Januari 2018
Y	3 Januari 2008 - 2 Januari 2018

Tabel 4.3 Variabel Input 1 Periode

<i>Close price</i> (D1)	Kurs Jual (E1)	Target <i>Close price</i> (Y)
2731.51	9,417	2715.06
2715.06	9,460	2765.19
2765.19	9,471	2776.41
2776.41	9,501	2785.63
2785.63	9,502	2830.26
2830.26	9,512	2810.37
2810.37	9,474	2730.03
2730.03	9,478	2592.31
2592.31	9,488	2649.28
...
...
6314.04	13,628	6355.65
6355.65	13,616	6339.24

Rancangan Dua Periode :

Dilakukan peramalan dengan menggunakan dua periode variabel input untuk meramalkan satu periode kedepan.

Tabel 4.4 Data Input 2 Periode

D1	2 Januari 2008 - 28 Januari 2018
E1	2 Januari 2008 - 28 Januari 2018
D2	3 Januari 2008 - 29 Desember 2017
E2	3 Januari 2008 - 29 Desember 2017
Y	4 Januari 2008 - 2 Januari 2018

Tabel 4.5 Variabel Input 2 Periode

D1	E1	D2	E2	Y
2731.51	9,417	2715.06	9,460	2765.19
2715.06	9,460	2765.19	9,471	2776.41
2765.19	9,471	2776.41	9,501	2785.63
2776.41	9,501	2785.63	9,502	2830.26
2785.63	9,502	2830.26	9,512	2810.37
2830.26	9,512	2810.37	9,474	2730.03
...
6314.04	13,628	6355.65	13,616	6339.24

Rancangan Tiga Periode :

Dilakukan peramalan dengan menggunakan tiga periode variabel input untuk meramalkan satu periode kedepan.

Tabel 4.6 Data Input 3 Periode

D1	2 Januari 2008 - 27 Januari 2018
E1	2 Januari 2008 - 27 Januari 2018
D2	3 Januari 2008 - 28 Desember 2017
E2	3 Januari 2008 - 28 Desember 2017
D3	4 Januari 2008 - 29 Desember 2017
E3	4 Januari 2008 - 29 Desember 2017
Y	7 Januari 2008 - 2 Januari 2018

Tabel 4.7 Variabel Input 3 Periode

D1	E1	D2	E2	D3	E3	Y
2731.51	9417	2715.06	9460	2765.19	9471	2776.41
2715.06	9460	2765.19	9471	2776.41	9501	2785.63
2765.19	9471	2776.41	9501	2785.63	9502	2830.26
2776.41	9501	2785.63	9502	2830.26	9512	2810.37
2785.63	9502	2830.26	9512	2810.37	9474	2730.03
...
6277.17	13630	6314.05	13628	6355.65	13616	6339.24

Rancangan Empat Periode :

Dilakukan peramalan dengan menggunakan empat periode variabel input untuk meramalkan satu periode kedepan.

Tabel 4.8 Data Input 4 Periode

D1	2 Januari 2008 - 22 Januari 2018
E1	2 Januari 2008 - 22 Januari 2018
D2	3 Januari 2008 - 27 Desember 2017
E2	3 Januari 2008 - 27 Desember 2017
D3	4 Januari 2008 - 28 Desember 2017
E3	4 Januari 2008 - 28 Desember 2017
D4	7 Januari 2008 - 29 Desember 2017
E4	7 Januari 2008 - 29 Desember 2017
Y	8 Januari 2008 - 2 Januari 2018

Tabel 4.9 Variabel Input 4 Periode

D1	E1	D2	E2	D3	E3	D4	E4	Y
2732	9417	2715	9460	2765	9471	2776	9501	2786
2715	9460	2765	9471	2776	9501	2786	9502	2830
2765	9471	2776	9501	2786	9502	2830	9512	2810
2776	9501	2786	9502	2830	9512	2810	9474	2730
2786	9502	2830	9512	2810	9474	2730	9478	2592
...
6221	13626	6277	13630	6314	13628	6356	13616	6339

Rancangan Lima Periode :

Dilakukan peramalan dengan menggunakan lima periode variabel input untuk meramalkan satu periode kedepan.

Tabel 4.10 Data Input 5 Periode

D1	2 Januari 2008 - 21 Januari 2018
E1	2 Januari 2008 - 21 Januari 2018
D2	3 Januari 2008 - 22 Desember 2017
E2	3 Januari 2008 - 22 Desember 2017
D3	4 Januari 2008 - 27 Desember 2017
E3	4 Januari 2008 - 27 Desember 2017
D4	7 Januari 2008 - 28 Desember 2017
E4	7 Januari 2008 - 28 Desember 2017
E5	8 Januari 2008 - 29 Desember 2017
E5	8 Januari 2008 - 29 Desember 2017
Y	9 Januari 2008 - 2 Januari 2018

Tabel 4.11 Variabel Input 5 Periode

D1	E1	D2	E2	...	D5	E5	Y
2732	9417	2715	9460	...	2786	9502	2830
2715	9460	2765	9471	...	2830	9512	2810
2765	9471	2776	9501	...	2810	9474	2730
2776	9501	2786	9502	...	2730	9478	2592
2786	9502	2830	9512	...	2592	9488	2649
...
6183	13647	6221	13613	...	6356	13616	6339

Perancangan dilakukan terus menerus dengan menambahkan data historis periode – periode sebelumnya dan dilakukan proses training dan testing pada model yang didapatkan hingga didapatkan model yang memiliki nilai MSE paling kecil.

4.4 Perancangan Model ANN

Pada tahap ini dilakukan perancangan model Artificial Neural Network, sehingga didapatkan berbagai varian model yang nantinya akan diimplementasikan dan dilakukan pengujian performa dengan MSE untuk menemukan model dengan hasil terbaik.

4.4.1 Pembagian Data

Setelah data diolah dan siap digunakan, dilakukan pembuatan model ANN dengan mempersiapkan data untuk training dan testing. Untuk data training sebanyak 75% yaitu 1830 data yang digunakan mulai dari 2 Januari 2008 – 29 Juni 2015 dan untuk data testing sebanyak 25% yaitu 610 data yang digunakan mulai dari 30 Juni 2015 – 2 Januari 2018.

4.4.2 Model Neural Network

Dalam perancangan model terbaik, dibutuhkan uji coba terhadap model yang telah dibuat. Hasil dari uji coba tersebut adalah model dengan hasil MSE paling rendah. Uji coba dilakukan dengan melakukan kombinasi antara *input layer* dan jumlah *hidden layer*. Percobaan dilakukan sebanyak tiga kali untuk setiap model parameter.

4.4.3 Penentuan *Input layer*

Model yang dibuat memiliki *input layer* yang berisi data historis closed price, dan data kurs jual nilai tukar IDR – USD. Jumlah node pada *input layer* juga bervariasi antara 2 sampai 20 node layer. Pada periode 1, node input yang digunakan adalah 2, dan pada periode 2, node input yang digunakan adalah 4. Node input dapat digambarkan dengan nilai $2n$, dengan n adalah jumlah periode yang digunakan dalam peramalan.

4.4.3 Penentuan *Hidden layer*.

Jumlah dari neuron pada *hidden layer* ditentukan dalam proses *trial-error* yang berkisaran antara $n - 2n$ dari jumlah node *input layer*. Variasi jumlah *hidden layer* adalah 2 sampai dengan 40 node sesuai dengan jumlah node input yang ada.

4.4.4 Penentuan Parameter

Pada penelitian ini dilakukan perubahan parameter – parameter yang ada untuk menentukan model terbaik, yaitu model yang memiliki MSE paling rendah diantara kombinasi parameter yang ada.

Berikut merupakan penjelasan mengenai parameter – parameter yang digunakan :

a. *Epoch*

Epoch merupakan parameter yang mendefinisikan jumlah literasi yang akan dijalankan pada sebuah model. Jumlah *epoch* akan mempengaruhi performa sebuah model, dikarenakan *epoch* menentukan kapan proses training pada model berhenti. Jumlah *epoch* yang digunakan pada penelitian ini yaitu 100 *epoch*. Nilai *epoch* 100 didapatkan dari proses *trial error* dari pengecekan performa yang dilakukan pada model. Dilakukan percobaan dengan *epoch* 1000 dan 100 untuk melihat titik konvergen, dan didapatkan titik konvergen pada nilai 100, sehingga tidak terdapat penurunan MSE yang signifikan pada *epoch* 1000, sehingga pada percobaan ini menggunakan 100 *epoch*.

b. *Momentum*

Momentum merupakan suatu titik perubahan terhadap bobot model ANN. *Momentum* yang digunakan dicari dengan proses trial dan error pada model yang ada, dan mencari model yang memiliki nilai MSE terkecil. *Momentum* yang digunakan adalah antara 0.1 hingga 0.9. *Momentum* merepresentasikan peningkatan pada weight dan bias, semakin tinggi momentum, maka peningkatan weight dan bias akan semakin tinggi pada setiap literasi, sehingga walaupun mengurangi waktu yang dibutuhkan pada proses training model, hal ini akan mengakibatkan proses kurang teliti dalam training modelnya.

c. *Learning rate*

Learning rate merupakan parameter yang mendefinisikan kecepatan pembelajaran sebuah model, yaitu berapa lama waktu yang dibutuhkan untuk mencapai solusi paling minimum. Parameter *learning rate* didefinisikan dari 0.1 hingga 0.9 dengan proses trial error untuk mengetahui model terbaik. *Learning rate* merepresentasikan kecepatan pembelajaran dalam proses training model, semakin tinggi *learning rate* akan mengurangi waktu yang dibutuhkan dalam proses pembelajaran saat training model.

d. Fungsi Pembelajaran (*Learning Function*)

Pada penelitian ini, *Learning Function* yang digunakan adalah *learnsgdm*. *Learnsgdm* digunakan untuk mencari gradient yang paling optimal terhadap weight dan bias pada model. *Learnsgdm* digunakan dalam fungsi pembelajaran karena pada penelitian kali ini parameter yang digunakan mencakup *learning rate* dan momentum.

e. Fungsi Transfer (*Transfer function*)

Fungsi transfer pada model ditentukan dengan proses trial dan error. Jenis yang digunakan adalah *Logsigmoid (logsig)*, *Tansigmoid (tansig)*, dan *Purelinear(purelin)*. Ketiga fungsi tersebut digunakan pada layer pertama, sedangkan *output layer* menggunakan *purelin* untuk fungsi transfernya. Fungsi transfer berguna untuk mendapatkan nilai dari pengolahan weight pada model.

f. Fungsi Pelatihan (*Training function*)

Fungsi pelatihan yang digunakan pada penelitian ini adalah *traingdx*, *traingda*, dan *trainlm*. Diharapkan dengan proses trial dan error akan mendapatkan model terbaik dengan hasil MSE terkecil.

Pada tabel 4.12, akan dijabarkan rancangan arsitektur dari model ANN yang akan dibuat :

Tabel 4.12 Rancangan Struktur Model ANN

Parameter	Nilai	Deskripsi
<i>Hidden layer</i>	n, n+1,.....2n	Trial Error
<i>Epoch</i>	100	Trial Error
<i>Momentum</i>	0.1 hingga 0.9	Trial Error
<i>Learning rate</i>	0.1 hingga 0.9	Trial Error
<i>Learning Function</i>	1	Learngdm
<i>Transfer function</i>	3	Trial Error
<i>Training function</i>	3	Trial Error
<i>Output layer</i>	1 neuron	Nilai <i>close price</i> periode selanjutnya

Halaman ini sengaja dikosongkan


BAB V

IMPLEMENTASI

Bab ini menjelaskan implementasi terhadap model *Artificial Neural Network* untuk melakukan prediksi terhadap nilai *close price* indeks harga saham gabungan Indonesia.

5.1 Pembagian Data

Data yang digunakan adalah data harian *close price* indeks harga saham gabungan Indonesia dan kurs jual IDR – USD pada tahun 2008 – 2018. Data yang didapatkan berjumlah 2441 untuk masing – masing data indeks dan kurs. Dalam pengolahan data, data dibagi menjadi 2 bagian, yaitu data pelatihan (training) dan data pengujian (testing). Untuk data training sebanyak 75% yaitu 1830 data dan untuk data testing sebanyak 25% yaitu 610 data yang ditunjukkan pada gambar 5.1 dan 5.2 .



Gambar 5.1 Data Training



Gambar 5.2 Data Testing

5.2 Pembuatan Model Artificial Neural Network

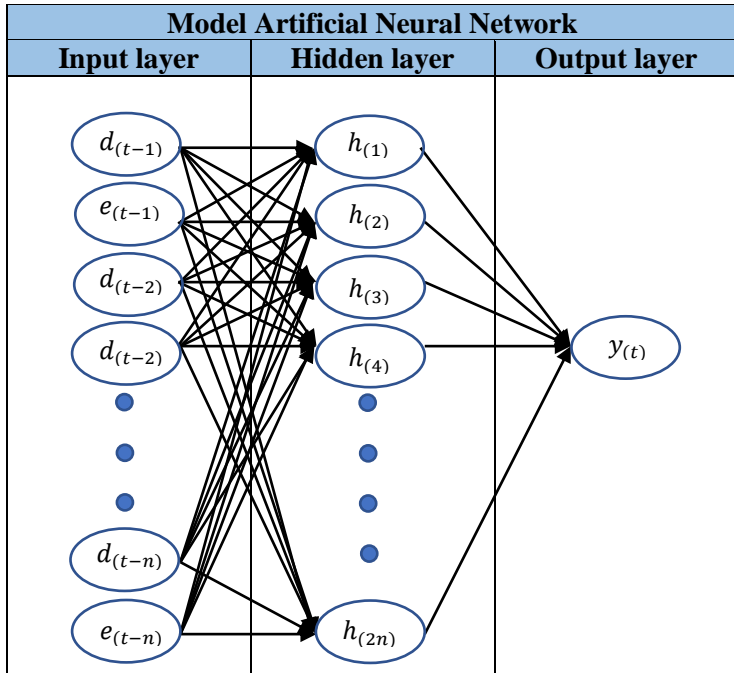
Pembuatan model ANN dirancang sesuai dengan arsitektur model ANN yang terdapat *input layer*, *hidden layer* dan *output layer*.

5.2.1 Model Artificial Neural Network

Pada penelitian ini, model Artificial Neural Network terdiri dari *input layer*, *hidden layer*, dan *output layer*. *Input layer* berisi *close price* indeks harga saham gabungan periode sebelumnya, *hidden layer* terdiri dari satu layer yang berisi fungsi aktivasi, dan *output layer* yang memiliki satu neuron, yaitu target *close price*. Persamaan dalam model ANN penelitian ini adalah sebagai berikut :

$$y_{(t)} = f(d_{(t-1)}, e_{(t-1)}, d_{(t-2)}, e_{(t-2)} \dots \dots \dots, d_{(t-n)}, e_{(t-n)})$$

Hidden layer = dimulai dari n node input layer hingga 2n node input layer ($h_{(1)}, h_{(2)}, h_{(3)}, h_{(4)}, h_{(5)}, h_{(6)} \dots \dots \dots, h_{(2n)}$)



Gambar 5.3 Model Artificial Neural Network

Penjelasan gambar 5.3 :

- n = Jumlah node input pada input layer
- $d_{(t-1)}$ = Data input *close price* 1 hari sebelumnya
- $e_{(t-1)}$ = Data input kurs jual 1 hari sebelumnya
- $d_{(t-2)}$ = Data input *close price* 2 hari sebelumnya
- $d_{(t-2)}$ = Data input kurs jual 2 hari sebelumnya
- $d_{(t-n)}$ = Data input *close price* n hari sebelumnya
- $d_{(t-n)}$ = Data input kurs jual n hari sebelumnya
- $h_{(1)}$ = 1 node pada *hidden layer*
- $h_{(2)}$ = 2 node pada *hidden layer*
- $h_{(3)}$ = 3 node pada *hidden layer*
- $h_{(4)}$ = 4 node pada *hidden layer*
- $h_{(2n)}$ = 2n node pada *hidden layer*
- $y_{(t)}$ = Data *close price* output

5.2.2 Data Input

Data yang digunakan untuk data input dalam penelitian ini adalah data harian indeks harga saham gabungan Indonesia, dan data kurs jual IDR – USD dari 2 Januari 2008 hingga 2 Januari 2018. Data terdiri dari tanggal dan harga. Variabel yang menjadi input dalam penelitian ini adalah harga saham gabungan dan harga kurs jual, sehingga node pada *input layer* memiliki dua node.

Dilakukan penambahan node pada *input layer* untuk mengetahui model node input yang memiliki hasil MSE terbaik. Penambahan node dilakukan dengan memasukkan data pertama pada periode ke $n+1$ pada data kedua, dan memasukkan data ke $n+2$ pada data ketiga dan seterusnya sejumlah node. Pada penelitian ini *input layer* memiliki 2 hingga 20 node.

5.2.3 Data Output

Data output yang digunakan pada penelitian ini menggunakan satu variabel, sehingga memiliki satu node output. Ketika data input yang digunakan adalah data ke- n , maka output yang dihasilkan adalah data ke $n+1$. Jika data input adalah data ke $n+1$, maka data outnya adalah data ke $n+2$, pola berlangsung hingga seterusnya.

5.2.4 Parameter Model

Pada pembuatan model pada penelitian ini, parameter yang digunakan adalah *Epoch*, *Momentum*, *Learning rate*, *Learning Function*, *Training function*, dan *Transfer function*. Parameter tersebut sudah dijelaskan pada bab sebelumnya.

5.3 Penerapan Model Artificial Neural Network

Pembuatan script ditujukan untuk melakukan otomatisasi pembuatan model dengan mengubah parameter – parameter yang ada. Script dijalankan pada aplikasi Matlab dan akan mencari model yang paling optimal.

5.3.1 Deskripsi Parameter

Pada awal script, dilakukan pendeskripsian parameter – parameter yang digunakan. Sebelum dilakukan proses training dan pembuatan network, perlu dijelaskan parameter – parameter apa saja yang digunakan dalam pembuatan model. Parameter digunakan untuk melakukan otomatisasi proses training model dalam parameter yang berbeda – beda.

```
transferFunc={'logsig' 'tansig' 'purelin'};
trainingFunc={'traingdx' 'traingda' 'trainlm'};
learningFunc={'learngdm'};
momentum=[0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9];
epoch=[100];
learningrateFunc=[0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9];
```

Script 5.1 Deskripsi Parameter

Pada tabel 5.1 akan dijabarkan mengenai penjelasan script parameter yang digunakan :

Tabel 5.1 Penjelasan Script Parameter

Script	Fungsi
transferFunc	Penentuan fungsi transfer.
trainingFunc	Mendeskripsikan fungsi training.
learningFunc	Penentuan fungsi pembelajaran.
Momentum	Mendeksripsikan array pada fungsi momentum
Epoch	Penentuan jumlah literasi yang akan dijalankan dalam pembuatan model.
learningrateFunc	Mendeskripsikan array pada fungsi learningrate

5.3.2 Fungsi Perulangan

Setelah dilakukan pendeskripsian parameter, dilakukan pembuatan fungsi perulangan agar sistem dapat membuat model dan mengeluarkan output peramalan secara otomatis tanpa harus mengganti parameter satu per satu.

```
A=numel(transferFunc);
B=numel(trainingFunc);
C=numel(learningFunc);
D=numel(momentum);
E=numel(epoch);
F=numel(learningrateFunc);

for node=2:40
    for a=1:A
        for b=1:B
            for c=1:C
                for d=1:D
                    for e=1:E
                        for f=1:F
```

Script 5.2 Fungsi Perulangan

Pada tabel 5.2 akan dijabarkan mengenai penjelasan script perulangan yang digunakan :

Tabel 5.2 Penjelasan Script Perulangan

Script	Fungsi
numel	Membaca jumlah elemen yang ada pada array parameter yang telah dideskripsikan.
node	Mendeskripsikan jumlah node <i>hidden layer</i> yang akan dijalankan.

Perulangan dilakukan pada semua parameter yang telah dijelaskan pada awal script. Perulangan diawali dengan node *hidden layer*, kemudian mengambil indeks array dari parameter transferFunc (A), kemudian parameter trainingFunc (B), learningFunc (C), indeks momentum (D), *epoch* (E), dan

learningrateFunc (F). Perulangan dilakukan dari indeks 1 pada masing – masing parameter dan berlangsung hingga jumlah elemen pada parameter.

5.3.3 Pembuatan Struktur Neural Network

Setelah perulangan didefinisikan, dilakukan pembuatan struktur untuk neural network.

```
net=newff(inputTraining, targetTraining, node_
{cell2mat(transferFunc(a)), 'purelin'});
net.trainFcn=cell2mat(trainingFunc(b));
net.trainParam.lr=learningrateFunc(c);
net.trainParam.mc=momentum(d);
net.trainParam.epochs=epoch(e);
net.trainParam.max_fail=1000;
net.layerWeights{1,1}.learnFcn=cell2mat(learningFunc(f));
```

Script 5.3 Pembuatan Neural Network

Pada tabel 5.3, akan dijelaskan mengenai rincian script pembuatan struktur neural network :

Tabel 5.3 Penjelasan Script Pembuatan Neural Network

Script	Fungsi
net	Pendeskripsian pembuatan network.
newff	Penjelasan jenis network, yaitu feedforward backpropagation
inputTraining	Membaca dataset dari workspace untuk data input proses training.
targetTraining	Membaca dataset dari workspace untuk data target training.
Node	Pendeskripsian node <i>hidden layer</i> .

Script	Fungsi
Cell2mat(transferFunc(a))	Membaca parameter <i>transfer function</i> yang akan digunakan pada <i>hidden layer</i> .
Purelin	Pendeklarasian <i>transfer function</i> yang digunakan pada <i>output layer</i> , yaitu purelin.
Net.trainFcn	Melakukan proses training pada data.
Cell2mat(trainingFunc(b))	Membaca parameter <i>training function</i> yang akan digunakan pada <i>hidden layer</i> .
Net.trainParam.lr	Menentukan parameter <i>learning rate</i> yang digunakan.
learningrateFunc(c)	Membaca parameter <i>learningrate function</i>
Net.trainParam.mc	Menentukan parameter momentum yang digunakan.
Momentum(d)	Membaca parameter momentum
Net.trainParam.epoch	Menentukan parameter <i>epoch</i> yang digunakan.
Epoch(e)	Membaca parameter <i>epoch</i>
Net.trainParam.max_fail	Mendeskripsikan maksimum fail pada proses training, agar proses literasi berlangsung hingga mencapai nilai <i>epoch</i> .
Net.layerWeights{1,1}.learnFcn	Menentukan parameter <i>Learning Function</i> yang digunakan.
Cell2mat(learningFunc(f))	Membaca parameter <i>Learning Function</i> yang akan digunakan pada <i>hidden layer</i> .

5.3.4 Proses Training dan Testing

Setelah struktur network dibuat, selanjutnya dilakukan proses training dan testing pada data. Pada script 5.4 akan dijabarkan mengenai script training dan testing data.

```
[netTrain, tr]=train(net, inputTraining, targetTraining);
outputTraining=net(inputTraining);
outputTesting=sim(net, inputTesting);
```

Script 5.4 Proses Training dan Testing

Pada tabel 5.4, akan dijelaskan mengenai rincian script training dan testing data :

Tabel 5.4 Penjelasan Script Training dan Testing

Script	Fungsi
netTrain, tr	Melakukan penyimpanan dan pengambilan model pada network.
train	Menjalankan fungsi training pada Matlab.
sim	Menjalankan fungsi testing (simulation) pada Matlab.
inputTraining	Mengambil dataset pada workspace yang berisi data input dari proses training.
targetTraining	Mengambil dataset pada workspace yang berisi data target output dari proses training.
outputTraining	Melakukan penyimpanan hasil dari proses training.
outputTesting	Melakukan penyimpanan hasil dari proses testing.

Proses training dan testing dijalankan sebanyak tiga kali untuk setiap model, yang hasilnya akan disimpan dalam file excel untuk mempermudah proses pengolahan hasil.

5.3.5 Penyimpanan Model Matlab

Setelah proses training dan testing pada data selesai, dilakukan penyimpanan model dalam bentuk .mat . Pada script 5.5 akan dijabarkan mengenai script penyimpanan model.

```
hasilTrain=transpose(hasilTrain);
hasilSim=transpose(hasilSim);
ModelNameNet=[num2str(a), '_', num2str(b), '_',
num2str(d), '_', num2str(f), '_', num2str(node),'netTrain','.mat'];
save(ModelNameNet, 'netTrain');
```

Script 5.5 Proses Training dan Testing

Pada tabel 5.5 , akan dijelaskan mengenai rincian script penyimpanan model :

Tabel 5.5 Penjelasan Script Penyimpanan Model

Script	Fungsi
hasilTrain	Variabel penyimpanan dari output dalam proses training
hasilSim	Variabel penyimpanan dari output dalam proses testing
transpose	Melakukan fungsi transpose pada data
ModelNameNet	Melakukan penamaan pada model yang sudah dibuat
Num2str	Mengubah penomoran indeks menjadi tipe string, agar dapat diambil sebagai format penamaan
Save(ModelNameNet)	Melakukan penyimpanan model sesuai nama yang telah dibuat

5.3.6 Penyimpanan Hasil Training dan Testing

Setelah proses penyimpanan model dalam bentuk .mat, dilakukan penyimpanan hasil peramalan dalam excel. Pada script 5.6 akan dijabarkan mengenai script penyimpanan hasil.

```
Excel = actxserver ('Excel.Application');
File='d:\Kuliah\Semester 8\TA\Output.csv';
if ~exist (File, 'file')
ExcelWorkbook = Excel.workbooks.Add;
ExcelWorkbook.SaveAs (File,1);
ExcelWorkbook.Close (false);
end
invoke (Excel.Workbooks, 'Open', File);

fileNameoutputTraining=[num2str(a), '_', num2str(b), '_'_
num2str(d), '_', num2str(f), '_', num2str(node), 'netTrain', '.xls'];
fileNameoutputTesting=[num2str(a), '_', num2str(b), '_'_
num2str(d), '_', num2str(f), '_', num2str(node), 'netTest', '.xls'];
xlswrite (fileNameoutputTraining,outputTraining);
xlswrite (fileNameoutputTesting,outputTesting);
```

Script 5.6 Penyimpanan Hasil Training dan Testing

Pada tabel 5.6, akan dijelaskan mengenai rincian script penyimpanan output training dan testing dari network :

Tabel 5.6 Penjelasan Script Save Hasil

Script	Fungsi
Excel = actserver	Membuka aplikasi excel, dan membuat active sheet pada excel
File	Mendeskripsikan lokasi file excel yang akan dibuat
fileName	Melakukan penamaan pada file yang akan disimpan, ditambahkan .xls untuk menyimpan dalam format excel

Script	Fungsi
Num2str	Mengubah penomoran indeks menjadi tipe string, agar dapat diambil sebagai format penamaan
xlswrite	Melakukan penyimpanan hasil training dan testing sesuai nama yang telah dibuat dalam format excel

5.3.7 Fungsi MSE

Script paling akhir yang dijalankan adalah script mengenai fungsi uji performa menggunakan MSE. Script dijalankan dengan melakukan penghitungan target training yang dikurangi output training, kemudian dipangkatkan dua. Kemudian hasil dirata-rata sehingga mendapatkan nilai MSE.

```
mseTrain=(targetTraining-outputTraining).^2;
mseTrain=mean(mseTrain);
xlswrite(fileNamemseTrain,mseTrain);
```

Script 5.7 Penghitungan MSE

Pada tabel 5.7, akan dijelaskan mengenai rincian script penyimpanan MSE :

Tabel 5.7 Penjelasan Script Uji Performa MSE

Script	Fungsi
mseTrain	Mendefinisikan variabel uji performa MSE pada model.
Mean(mseTrain)	Menghitung rata – rata hasil dari suatu penghitungan variabel mseTrain.
xlswrite	Melakukan saving hasil MSE pada excell

Setelah model dan hasil output disimpan dalam excel, maka data dapat diolah dan dianalisa, sehingga memberikan hasil analisis dan dapat dibahas pada bab selanjutnya.

Halaman ini sengaja dikosongkan

BAB VI

ANALISIS HASIL DAN PEMBAHASAN

Dalam bab ini, akan dijelaskan mengenai hasil dan pembahasan terkait prediksi terhadap nilai *close price* indeks harga saham gabungan di Indonesia. Pada bab ini juga dijabarkan pembahasan mengenai penentuan parameter yang paling optimal untuk model ANN yang akan digunakan untuk melakukan prediksi terhadap nilai *close price*.

6.1 Lingkungan Uji Coba

Lingkungan uji coba merupakan kriteria perangkat yang digunakan dalam melakukan percobaan untuk mendapatkan model ANN yang optimal pada penelitian ini. Lingkungan uji coba pada penelitian ini terdiri dari perangkat keras (hardware) dan perangkat lunak (software). Lingkungan perangkat keras yang digunakan pada penelitian ini ditunjukkan pada tabel 6.1.

Tabel 6.1 Lingkungan Perangkat Keras

Perangkat Keras	Spesifikasi
Jenis	Laptop
Processor	AMD A8
RAM	4 GB
Hard Disk Drive	1 TB

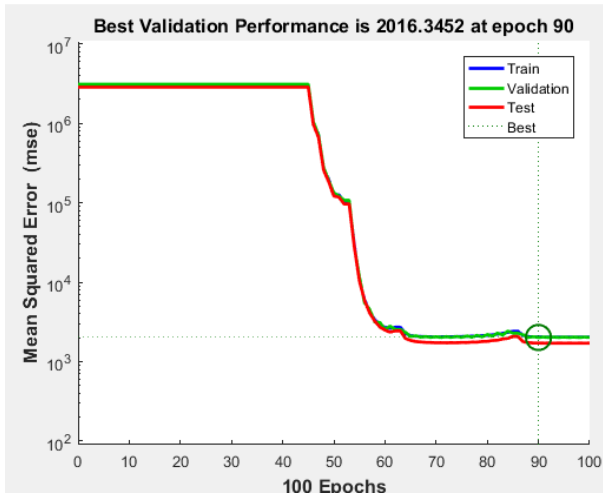
Sedangkan lingkungan perangkat lunak yang digunakan pada penelitian ini ditunjukkan pada tabel 6.2.

Tabel 6.2 Lingkungan Perangkat Lunak

Perangkat Lunak	Fungsi
Windows 10	Sistem Operasi
Matlab R2013	Pembuatan model, proses training, testing, dan peramalan.
Microsoft Excel 2016	Pengolahan data dan analisis hasil.

6.2 Percobaan Parameter

Dilakukan uji coba dengan parameter yang ada, apakah terdapat kombinasi yang tidak menghasilkan output atau tidak. Dan hasilnya semua parameter tidak mengeluarkan nilai null, sehingga dapat dilakukan percobaan terhadap model yang ada. Parameter yang digunakan pada penelitian ini salah satunya adalah parameter epoch, setelah dilakukan uji performa pada *epoch* 1000 dan 100, didapatkan *epoch* sudah konvergen pada nilai 100, sehingga ketika dilakukan percobaan hingga 1000 *epoch*, tidak menunjukkan penurunan nilai MSE yang signifikan. Nilai *epoch* yang sudah konvergen dibuktikan pada gambar 6.1



Gambar 6.1 Parameter Epoch

6.3 Percobaan Model

Pada bab ini dijelaskan mengenai proses percobaan pada model yang telah dilakukan. Jumlah model berdasarkan varian parameter yang ada, yaitu 3 *transfer function*, 3 *training function*, 9 momentum, dan 9 learningrate. Varian dikalikan dengan jumlah node *hidden layer* sehingga menghasilkan jumlah model yang ada.

Pada tabel 6.3 akan dijabarkan jumlah model pada setiap node input :

Tabel 6.3 Jumlah Model Tiap Node

Node Input	Jumlah Model
2	2187
4	3746
6	5130
8	6561
10	8019
12	9477
14	10935
16	12393
18	13852
20	15309

Jumlah model bergantung pada varian parameter dan jumlah *hidden layer*, yaitu pada setiap node *hidden layer* menghasilkan 729 model. Jumlah *hidden layer* berkisar antara jumlah node input hingga dua kali node input.


6.3.1 Model Node Input 2

Pada percobaan pertama, dilakukan proses training dan testing untuk model dengan kombinasi parameter *training function*, *transfer function*, momentum, dan *learning rate*. Model yang didapatkan pada percobaan dengan 2 node input adalah 2187 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga. Tabel pada percobaan dengan 2 node input akan ditampilkan pada tabel 6.4


Tabel 6.4 Hasil Model 2 Node Input

Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
2	Purelin	Traingda	0.9	0.5	1865	1890	1871
3	Purelin	Traingda	0.3	0.2	1865	1880	1889
4	Purelin	Traingda	0.6	0.7	1866	1868	1866

Hasil perbandingan nilai MSE akan diperjelas pada gambar 6.2 untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.

**Gambar 6.2 Perbandingan MSE Node Input 2**

Sesuai dengan tabel 6.4 dan gambar 6.2, dapat disimpulkan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 3 dengan nilai MSE 1865.48. Model terbaik pada 3 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training traingda, *momentum constanta* 0.3, learningrate 0.2, dan *epoch* 100. Setelah mendapatkan model terbaik, dapat dibuat plot data aktual dan data prediksi untuk melihat perbedaan antara data aktual dan prediksi



Gambar 6.3 Plot Data Node Input 2

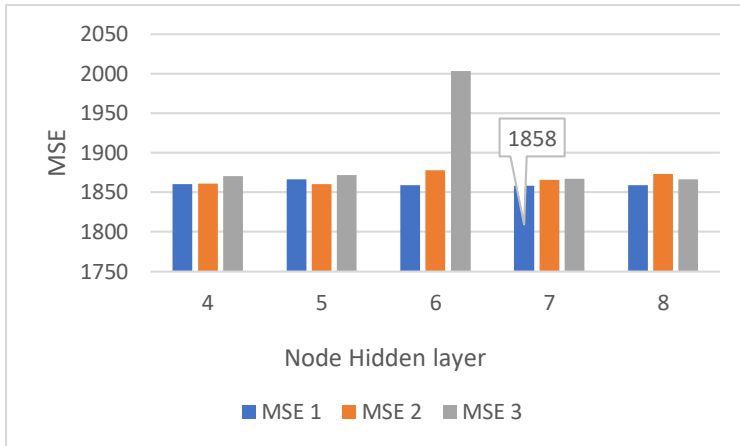
6.3.2 Model Node Input 4

Selanjutnya pada percobaan kedua, dilakukan proses training dan testing untuk model dengan 4 node input. Model yang didapatkan pada 4 node input adalah 5130 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga.

Tabel 6.5 Hasil Model 4 Node Input


Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
4	Purelin	Trainlm	0.5	0.5	1860	1861	1871
5	Purelin	Trainlm	0.7	0.8	1866	1861	1872
6	Purelin	Trainlm	0.1	0.2	1859	1878	2004
7	Purelin	Trainlm	0.3	0.3	1858	1866	1867
8	Purelin	Trainlm	0.5	0.8	1859	1873	1867

Hasil perbandingan nilai MSE akan diperjelas pada gambar 6.4 untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.4 Perbandingan MSE Node Input 4

Sesuai dengan tabel 6.5 dan gambar 6.4, dapat disimpulkan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 7 dengan nilai MSE 1858.48. Model terbaik pada 7 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.3 , learningrate 0.3 , dan *epoch* 100. Setelah mendapatkan model terbaik, dapat dibuat plot data aktual dan data prediksi untuk melihat perbedaan antara data aktual dan prediksi



Gambar 6.5 Plot Data Node Input 4


6.3.3 Model Node Input 6

Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 6 node input. Model yang didapatkan pada 6 node input adalah 3746 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga.

Tabel 6.6 Hasil Model 6 Node Input


Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
6	Purelin	Trainlm	0.5	0.1	1997	1860	1997
7	Purelin	Trainlm	0.6	0.3	1868	1910	1868
8	Purelin	Trainlm	0.6	0.9	1871	1876	1871
9	Purelin	Trainlm	0.8	0.4	1881	1865	1881
10	Purelin	Trainlm	0.3	0.7	1871	1920	1871
11	Purelin	Trainlm	0.8	0.8	1878	1910	1865
12	Purelin	Trainlm	0.7	0.7	1868	1868	1897

Hasil perbandingan nilai MSE akan diperjelas untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.6 Perbandingan MSE Node Input 6

Jika dilihat pada tabel 6.6 dan gambar 6.6 , dapat disimpulkan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 6 dengan nilai MSE 1859.94. Model terbaik pada 6 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.5 , learningrate 0.1 , dan *epoch* 100. Setelah mendapatkan model terbaik, dapat dibuat plot data aktual dan data prediksi untuk melihat perbedaan antara data aktual dan prediksi



Gambar 6.7 Plot Data Node Input 6


6.3.4 Model Node Input 8

Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 8 node input. Model yang didapatkan berjumlah 6561 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga.

Tabel 6.7 Hasil Model 8 Node Input


Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
8	Purelin	Trainlm	0.6	0.2	1907	1873	1849
9	Purelin	Trainlm	0.3	0.2	1892	1892	1850
10	Purelin	Trainlm	0.2	0.5	1851	1851	1850
11	Purelin	Trainlm	0.9	0.8	1848	1848	1885
12	Purelin	Trainlm	0.1	0.3	1850	1850	1863
13	Purelin	Trainlm	0.3	0.9	1846	1870	1877
14	Purelin	Trainlm	0.7	0.7	1847	1875	1862
15	Purelin	Trainlm	0.8	0.7	1874	1854	1880
16	Purelin	Trainlm	0.4	0.5	1878	1860	1849

Hasil perbandingan nilai MSE akan diperjelas dengan bar chart untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.8 Perbandingan MSE Node Input 8

Jika dilihat pada tabel 6.7 dan gambar 6.8 , dapat disimpulkan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 13 dengan nilai MSE 1846.10. Model terbaik pada 13 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.3 , learningrate 0.9 , dan *epoch* 100. Setelah mendapatkan model terbaik, dapat dibuat plot data aktual dan data prediksi untuk melihat perbedaan antara data aktual dan prediksi



Gambar 6.9 Plot Data Node Input 8

6.3.5 Model Node Input 10


Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 10 node input. Model yang didapatkan berjumlah 8019 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga. Tabel pada percobaan dengan 10 node input akan ditampilkan pada tabel 6.8

Tabel 6.8 Hasil Model 10 Node Input

Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
10	Purelin	Trainlm	0.1	0.5	1881	1879	1840
11	Purelin	Trainlm	0.7	0.7	1843	1843	1876
12	Purelin	Trainlm	0.3	0.3	1903	1887	1839
13	Purelin	Trainlm	0.3	0.9	1922	1850	1836

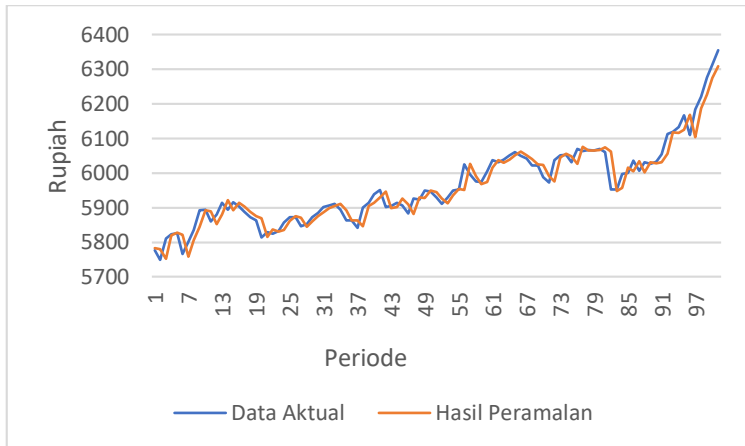
Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
14	Purelin	Trainlm	0.9	0.1	1903	1840	1858
15	Purelin	Trainlm	0.5	0.9	1870	1875	1841
16	Purelin	Trainlm	0.5	0.3	1879	1904	1846
17	Purelin	Trainlm	0.9	0.9	1878	1909	1843
18	Purelin	Trainlm	0.1	0.1	1838	1882	1878
19	Purelin	Trainlm	0.6	0.2	1844	1892	1865
20	Purelin	Trainlm	0.2	0.3	1864	1833	1889

Hasil perbandingan nilai MSE akan diperjelas pada gambar 6.10 untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.10 Perbandingan MSE Node Input 10

Jika dilihat dari hasil yang ada, dapat disimpulkan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 20 dengan nilai MSE 1846.10. Model terbaik pada 20 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.2 , learningrate 0.3 , dan *epoch* 100. Untuk mengetahui perbedaan hasil peramalan dan data aktual, dapat dilihat pada plot perbedaan data aktual dan data peramalan pada gambar 6.11



Gambar 6.11 Plot Data Node Input 10

6.3.6 Model Node Input 12


Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 12 node input. Model yang didapatkan berjumlah 9477 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga.

Tabel 6.9 Hasil Model 12 Node Input

Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
12	Purelin	Trainlm	0.9	0.6	1844	1880	1843
13	Purelin	Trainlm	0.3	0.4	1837	1867	1878
14	Purelin	Trainlm	0.2	0.2	2111	1856	1836
15	Purelin	Trainlm	0.8	0.6	1847	1877	1877
16	Purelin	Trainlm	0.1	0.1	1854	1847	1847
17	Purelin	Trainlm	0.9	0.7	1888	1850	1850


Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
18	Purelin	Trainlm	0.1	0.3	1844	1903	1849
19	Purelin	Trainlm	0.2	0.7	1842	1907	1903
20	Purelin	Trainlm	0.5	0.8	1878	1868	1843
21	Purelin	Trainlm	0.7	0.7	1835	1907	2033
22	Purelin	Trainlm	0.7	0.7	1846	1902	1868
23	Purelin	Trainlm	0.1	0.9	1861	1921	1834
24	Purelin	Trainlm	0.7	0.5	1886	1869	1849

Hasil perbandingan nilai MSE akan diperjelas pada gambar 6.12 untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.12 Perbandingan MSE Node Input 12

Dapat dilihat pada tabel 6.9 dan gambar 6.12, didapatkan kesimpulan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 23 dengan nilai MSE 1834.30. Model terbaik pada 23 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.1, learningrate 0.9, dan *epoch* 100.



Gambar 6.13 Plot Data Node Input 12

6.3.7 Model Node Input 14


Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 14 node input. Model yang didapatkan berjumlah 10935 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga.

Tabel 6.9 Hasil Model 14 Node Input

Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
14	Purelin	Trainlm	0.2	0.5	1899	1833	1899
15	Purelin	Trainlm	0.5	0.3	1872	1837	1872
16	Purelin	Trainlm	0.9	0.4	1834	1848	1834
17	Purelin	Trainlm	0.9	0.9	1835	1835	1835
18	Purelin	Trainlm	0.7	0.9	1835	1835	1835
19	Purelin	Trainlm	0.3	0.7	1843	1843	1843
20	Purelin	Trainlm	0.4	0.3	1840	1840	1840
21	Purelin	Trainlm	0.5	0.9	1829	1829	1829


Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
22	Purelin	Trainlm	0.2	0.5	1842	1842	1842
23	Purelin	Trainlm	0.3	0.3	1838	1875	1875
24	Purelin	Trainlm	0.7	0.9	1831	1870	1870
25	Purelin	Trainlm	0.6	0.1	1866	1828	1828
26	Purelin	Trainlm	0.3	0.3	1857	1829	1829
27	Purelin	Trainlm	0.3	0.1	1875	1841	1841
28	Purelin	Trainlm	0.9	0.5	1932	1839	1839

Hasil perbandingan nilai MSE akan diperjelas dengan bar chart untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.14 Perbandingan MSE Node Input 14

Jika diamati pada hasil yang ada, didapatkan kesimpulan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 25 dengan nilai MSE 1827.86. Model terbaik pada 25 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.6, learningrate 0.1, dan *epoch* 100.



Gambar 6.15 Plot Data Node Input 14

6.3.8 Model Node Input 16


Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 16 node input. Model yang didapatkan berjumlah 12393 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga.

Tabel 6.10 Hasil Model 16 Node Input

Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
16	Purelin	Trainlm	0.5	0.3	1862	1853	1819
17	Purelin	Trainlm	0.7	0.2	1875	1850	1820
18	Purelin	Trainlm	0.2	0.2	1870	1856	1826
19	Purelin	Trainlm	0.4	0.9	1864	1840	1825
20	Purelin	Trainlm	0.3	0.9	1821	1844	1892
21	Purelin	Trainlm	0.9	0.6	1825	1900	1872
22	Purelin	Trainlm	0.3	0.9	1820	1863	1874

Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
23	Purelin	Trainlm	0.3	0.1	1852	1847	1830
24	Purelin	Trainlm	0.7	0.4	1822	1850	1890
25	Purelin	Trainlm	0.4	0.3	1857	1871	1830
26	Purelin	Trainlm	0.1	0.4	1854	1878	1829
27	Purelin	Trainlm	0.6	0.8	1865	1866	1829
28	Purelin	Trainlm	0.6	0.9	1873	1871	1829
29	Purelin	Trainlm	0.8	0.3	1835	1853	1841
30	Purelin	Trainlm	0.1	0.7	1829	1871	1856
31	Purelin	Trainlm	0.5	0.4	1841	1834	1825
32	Purelin	Trainlm	0.6	0.5	1894	1835	1835


Hasil perbandingan nilai MSE akan diperjelas pada gambar 6.16 untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.16 Perbandingan MSE Node Input 16

Jika diamati pada tabel 6.10 dan gambar 6.16, didapatkan kesimpulan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 16 dengan nilai MSE 1818.92.

Model terbaik pada 16 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.5 , learningrate 0.3 , dan *epoch* 100. Setelah mendapatkan model terbaik, dapat dibuat plot data aktual dan data prediksi untuk melihat perbedaan antara data aktual dan prediksi



Gambar 6.17 Plot Data Node Input 16


6.3.9 Model Node Input 18

Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 18 node input. Model yang didapatkan berjumlah 13852 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga. Tabel pada percobaan dengan 18 node input akan ditampilkan pada tabel 6.11

Tabel 6.11 Hasil Model 18 Node Input


Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
18	Purelin	Trainlm	0.4	0.1	1828	1865	1881
19	Purelin	Trainlm	0.2	0.5	1893	1833	1837
20	Purelin	Trainlm	0.3	0.6	1844	1844	1826
21	Purelin	Trainlm	0.2	0.1	1828	1865	1862
22	Purelin	Trainlm	0.4	0.9	1830	1884	1857
23	Purelin	Trainlm	0.7	0.3	1848	1839	1828
24	Purelin	Trainlm	0.1	0.7	1879	1865	1822
25	Purelin	Trainlm	0.4	0.9	1833	1867	1879
26	Purelin	Trainlm	0.6	0.2	1821	1840	1896
27	Purelin	Trainlm	0.7	0.3	1844	1866	1832
28	Purelin	Trainlm	0.9	0.2	1842	1833	1862
29	Purelin	Trainlm	0.4	0.4	1852	1864	1829
30	Purelin	Trainlm	0.4	0.4	1834	1846	1862
31	Purelin	Trainlm	0.3	0.5	1854	1878	1828
32	Purelin	Trainlm	0.4	0.9	1863	1884	1835
33	Purelin	Trainlm	0.2	0.9	1849	1831	1872
34	Purelin	Trainlm	0.3	0.4	1832	1852	1867
35	Purelin	Trainlm	0.8	0.2	1831	1844	1831
36	Purelin	Trainlm	0.1	0.3	1836	1882	1836

Hasil perbandingan nilai MSE akan diperjelas dengan bar chart untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.18 Perbandingan MSE Node Input 18

Jika diamati pada tabel 6.11 dan gambar 6.18, didapatkan kesimpulan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 26 dengan nilai MSE 1821.14. Model terbaik pada 26 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.6 , learningrate 0.2 , dan *epoch* 100. Setelah mendapatkan model terbaik, dapat dibuat plot data aktual dan data prediksi untuk melihat perbedaan antara data aktual dan prediksi



Gambar 6.19 Plot Data Node Input 18


6.3.10 Model Node Input 20

Selanjutnya percobaan dilakukan proses training dan testing pada model dengan 20 node input. Model yang didapatkan berjumlah 15309 model. Dilakukan proses training dan testing sebanyak tiga kali untuk setiap modelnya, sehingga dihasilkan tabel yang menunjukkan jumlah node *hidden layer*, *transfer function*, *training function*, *momentum constanta*, *learning rate*, nilai MSE pertama, MSE kedua, dan MSE pengujian ketiga. Tabel pada percobaan dengan 20 node input akan ditampilkan pada tabel 6.12

Tabel 6.12 Hasil Model 20 Node Input


Node Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE 1	MSE 2	MSE 3
20	Purelin	Trainlm	0.1	0.5	1870	1828	1857
21	Purelin	Trainlm	0.7	0.8	1857	1868	1828
22	Purelin	Trainlm	0.7	0.1	1838	1847	1894
23	Purelin	Trainlm	0.4	0.4	1833	1863	1866
24	Purelin	Trainlm	0.7	0.5	1873	1862	1831
25	Purelin	Trainlm	0.6	0.9	1832	1875	1894
26	Purelin	Trainlm	0.7	0.5	1895	1827	1907
27	Purelin	Trainlm	0.9	0.7	1855	1883	1838
28	Purelin	Trainlm	0.8	0.5	1836	1868	1882
29	Purelin	Trainlm	0.8	0.6	1831	1868	1896
30	Purelin	Trainlm	0.4	0.9	1863	1862	1831
31	Purelin	Trainlm	0.2	0.3	1835	1933	1855
32	Purelin	Trainlm	0.2	0.5	1843	1873	1830
33	Purelin	Trainlm	0.1	0.5	1832	1864	1881
34	Purelin	Trainlm	0.7	0.5	1867	1872	1837
35	Purelin	Trainlm	0.3	0.7	1872	1838	1850
36	Purelin	Trainlm	0.6	0.3	1835	1842	1860
37	Purelin	Trainlm	0.1	0.5	1839	1851	1865
38	Purelin	Trainlm	0.4	0.5	1830	1836	1878
39	Purelin	Trainlm	0.6	0.5	1906	1837	1897
40	Purelin	Trainlm	0.2	0.7	1871	1901	1829

Hasil perbandingan nilai MSE akan diperjelas pada gambar 6.20 untuk menampilkan perbandingan nilai MSE dan menentukan nilai MSE yang paling minimum.



Gambar 6.20 Perbandingan MSE Node Input 20

Jika dilihat dari tabel 6.12 dan gambar 6.20, didapatkan kesimpulan bahwa nilai MSE terkecil terdapat pada jumlah node *hidden layer* 26 dengan nilai MSE 1827.38. Model terbaik pada 26 node *hidden layer*, memiliki model parameter dengan fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.7 , learningrate 0.5 , dan *epoch* 100. Setelah mendapatkan model terbaik, dapat dibuat plot data aktual dan data prediksi untuk melihat perbedaan antara data aktual dan prediksi



Gambar 6.21 Plot Data Node Input 20

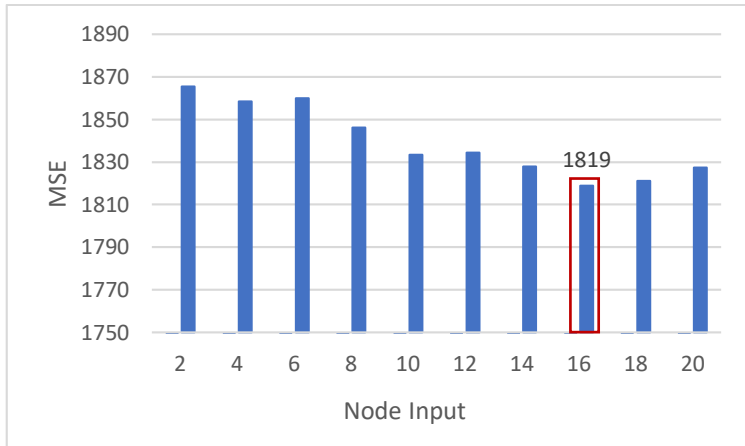
6.4 Kesimpulan Hasil Percobaan

Dari hasil percobaan yang dilakukan dengan pengubahan parameter – parameter yang ada, didapatkan model – model yang paling optimum pada setiap node input. Hasil model dengan parameter terbaik ditampilkan pada tabel 6.13 dan pada kolom terakhir ditampilkan nilai MSE pada setiap model terbaik.

Tabel 6.13 Kesimpulan Hasil Model

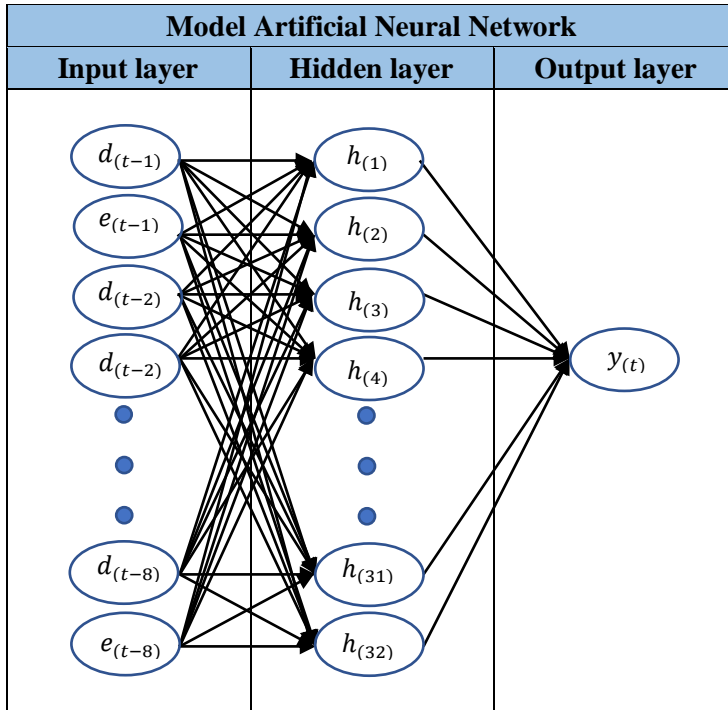
Input	Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE
2	3	purelin	Traingda	0.3	0.2	1865
4	7	purelin	Trainlm	0.3	0.3	1858
6	6	purelin	Trainlm	0.5	0.1	1860
8	13	purelin	Trainlm	0.3	0.9	1846
10	20	purelin	Trainlm	0.2	0.3	1833
12	23	purelin	Trainlm	0.1	0.9	1834
14	25	purelin	Trainlm	0.6	0.1	1828
16	16	purelin	Trainlm	0.5	0.3	1818
18	26	purelin	Trainlm	0.6	0.2	1821
20	26	purelin	Trainlm	0.7	0.5	1827

Kemudian data dipresentasikan dalam bentuk bar chart untuk memudahkan pemilihan model yang memiliki nilai MSE terkecil. Bar Chart perbandingan dapat dilihat pada gambar 6.22.



Gambar 6.22 Perbandingan MSE Node Input

Pada gambar 6.22, dapat disimpulkan bahwa nilai MSE terkecil terdapat pada node input 16 dengan nilai MSE 1818.92. Model terbaik pada node input 16, memiliki model parameter dengan jumlah *hidden layer* 16, fungsi transfer purelin, fungsi training trainlm, *momentum constanta* 0.6, *learning rate* 0.2, dan *epoch* 100. Untuk mengetahui nilai error yang lebih lanjut, dilakukan penghitungan MAPE, dan menghasilkan nilai MAPE sebesar 0.613 %



Gambar 6.23 Model ANN Terbaik

Penjelasan gambar 6.23 :

$d_{(t-1)}$ = Data input *close price* 1 hari sebelumnya

$e_{(t-1)}$ = Data input kurs jual 1 hari sebelumnya

$d_{(t-2)}$ = Data input *close price* 2 hari sebelumnya

$d_{(t-2)}$ = Data input kurs jual 2 hari sebelumnya

$h_{(16)}$ = 16 node pada hidden layer

$h_{(17)}$ = 17 node pada hidden layer

$h_{(18)}$ = 18 node pada hidden layer

$h_{(19)}$ = 19 node pada hidden layer


$h_{(31)}$ = 31 node pada hidden layer

$h_{(32)}$ = 32 node pada hidden layer

$y_{(t)}$ = Data *close price* output terbaik

6.5 Perbandingan Hasil Percobaan

Hasil yang didapatkan dengan metode pengolahan data dengan meniadakan data hari libur akan dibandingkan dengan metode pengolahan data time series dengan asumsi bahwa hari Sabtu, Minggu, dan hari libur nasional menggunakan data pada periode sebelumnya. Hal ini dilakukan sehingga tidak ada kerusakan dalam periode yang ada pada time series. Data yang akan digunakan dalam perbandingan hasil percobaan ditampilkan pada gambar 6.24




Gambar 6.24 Grafik Data Perbandingan

Data yang didapatkan dalam proses pengolahan time series berjumlah 3654 data. Dilakukan proses training dan testing pada data yang didapatkan. Proses training dan testing dijalankan pada 3 periode, dengan masing – masing berisi 2 node input layer, 4 node input layer, dan 6 node input layer. Hidden layer yang digunakan bernilai antara n hingga $2n$, dimana n adalah jumlah node input layer. Hasil model terbaik pada percobaan dengan data tersebut ditampilkan pada tabel 6.14

Tabel 6.14 MSE Model


Input	Hidden layer	Transfer Func	Train Func	Mc	Lr	MSE
2	3	purelin	Traingda	0.2	0.3	1245.37
4	6	purelin	Trainlm	0.3	0.8	1244.95
6	9	purelin	Trainlm	0.8	0.4	1245.70

Model yang didapatkan pada hasil training dan testing dengan menggunakan periode sebelumnya saat proses pre-processing data memiliki model (4,6,1) dengan nilai MSE 1244.957 dan MAPE 0.4215%. Model ditampilkan dalam bar chart dan dibandingkan dengan percobaan yang dilakukan dengan menghapus data nol. Bar chart ditampilkan dalam gambar 6.25

**Gambar 6.25 Perbandingan MSE A dan B**

MSE A menampilkan model dengan proses pre-processing data dengan meniadakan data hari libur, dan MSE B menampilkan model dengan proses pre-processing data dengan mengasumsikan data hari Sabtu, Minggu, dan hari libur menggunakan data pada periode sebelumnya.

Dapat dilihat bahwa dengan mengasumsikan data dengan periode sebelumnya, model memiliki performa yang lebih baik dibandingkan dengan meniadakan data hari libur. Ditampilkan juga grafik plotting model terbaik yang didapatkan dengan pre-processing menggunakan data sebelumnya, pada node input 4, hidden layer 6, transfer function purelin, training function trainlm, momentum constanta 0.2, dan learning rate 0.8. Grafik plotting model ditampilkan pada gambar 6.26



Gambar 6.26 Hasil Plotting Model B Terbaik

Walaupun hasil testing yang didapatkan dengan mengasumsikan data hari libur sama dengan data periode sebelumnya lebih baik dari hasil testing pengolahan data dengan meniadakan data hari libur, namun data yang didapatkan kurang fasible untuk digunakan dalam peramalan. Hal ini disebabkan karena data kosong yang diisi menggunakan periode sebelumnya mencapai 30% dari keseluruhan data. Menggunakan data pada periode sebelumnya untuk melakukan peramalan dapat menyebabkan hasil peramalan memiliki bias jika data yang kosong lebih dari 10%. [18] Sehingga tidak dianjurkan menggunakan data pada periode sebelumnya pada keseluruhan data kosong pada hari libur.

Pada penelitian selanjutnya, disarankan dilakukan proses pre-processing data dengan hanya meniadakan hari Sabtu dan Minggu, dan untuk data yang kosong pada hari libur nasional dapat diasumsikan sama dengan periode sebelumnya. Hal ini dianjurkan karena data kosong pada hari libur nasional hanya mencakup 5% dari keseluruhan data, sehingga data masih feasibel untuk digunakan dan tidak menimbulkan bias yang besar ketika dilakukan proses peramalan dan pembuatan model.

6.6 Hasil Peramalan


Setelah mendapatkan model yang paling optimum, maka dilakukan peramalan dengan mengimplementasikan model terbaik. Parameter – parameter yang telah didapatkan, akan dimasukkan kedalam kode, dan digunakan untuk melakukan proses peramalan. Pada tabel 6.15 ditampilkan sedikit hasil peramalan (data peramalan dapat dilihat pada lampiran B).

Tabel 6.15 Hasil Peramalan

Periode	Data Aktual	Hasil Peramalan
29-Nov-17	6061.37	6075.70
30-Nov-17	5952.14	6056.71
1-Dec-17	5952.14	5951.17
4-Dec-17	5998.19	5960.34
5-Dec-17	6000.47	6018.91
6-Dec-17	6035.51	6001.69
7-Dec-17	6006.83	6034.89
8-Dec-17	6030.96	6014.27
11-Dec-17	6026.63	6023.93
12-Dec-17	6032.37	6025.69
13-Dec-17	6054.60	6032.90
14-Dec-17	6113.65	6054.35
15-Dec-17	6119.42	6122.98
18-Dec-17	6133.96	6109.57
19-Dec-17	6167.67	6128.01

Periode	Data Aktual	Hasil Peramalan
20-Dec-17	6109.48	6169.25
21-Dec-17	6183.39	6101.42
22-Dec-17	6221.01	6181.63
27-Dec-17	6277.17	6232.52
28-Dec-17	6314.05	6270.14
2-Jan-18	6355.65	6306.93

Kemudian grafik hasil plotting peramalan dapat dilihat pada gambar 6.27.



Gambar 6.27 Plot Data Aktual dan Hasil Peramalan

Halaman ini sengaja dikosongkan

BAB VII

KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan yang dapat diambil dari keseluruhan penelitian yang dilakukan pada tugas akhir ini serta beberapa saran yang dapat dipertimbangkan untuk pengembangan tugas akhir ini.

7.1 Kesimpulan

Berdasarkan hasil penelitian, berikut ini merupakan beberapa kesimpulan yang dapat diambil.

1. Perancangan model ANN untuk memprediksi nilai *close price* indeks harga saham gabungan Indonesia menghasilkan arsitektur jaringan ANN dengan model terbaik pada Periode 8, dengan struktur ANN (16,16,1) pada pemrosesan data dengan meniadakan hari Sabtu, Minggu, dan hari libur nasional.
2. Perancangan model ANN untuk memprediksi nilai *close price* indeks harga saham gabungan Indonesia menghasilkan arsitektur jaringan ANN dengan model terbaik pada Periode 2, dengan struktur ANN (4,6,1) pada pemrosesan data dengan mengasumsikan data Sabtu, Minggu, dan hari libur nasional adalah sama dengan data periode sebelumnya.
3. Model yang digunakan adalah model ANN pada pemrosesan data dengan meniadakan hari Sabtu, Minggu, dan hari libur nasional. Hal ini disebabkan oleh nilai data yang hilang mencapai 30%, sehingga menimbulkan bias pada model yang mengasumsikan data Sabtu, Minggu, dan hari libur nasional adalah sama dengan data periode sebelumnya, sehingga hasil yang didapatkan kurang feasibel.

4. Model Artificial Neural Network dapat diterapkan untuk melakukan peramalan terhadap *close price* indeks harga saham gabungan Indonesia, karena memiliki akurasi MSE 1818.93 dengan MAPE 0.613% yang didapatkan pada testing model terbaik pada pemrosesan data dengan meniadakan hari Sabtu, Minggu, dan hari libur nasional.

7.2 Saran

Dalam pengerjaan tugas akhir ini masih terdapat hal-hal yang harus diperbaiki. Maka dari itu, didapatkan beberapa saran yang dapat menjadi bahan pertimbangan untuk pengembangan penelitian selanjutnya. Adapun saran yang diberikan yaitu :

1. Penelitian ini menggunakan variabel input *close price* indeks harga saham gabungan dan kurs jual IDR – USD, untuk penelitian selanjutnya dapat ditambahkan variabel lain seperti *open price*, *high price*, *low price* dan kurs nilai tukar negara lain untuk meningkatkan hasil peramalan.
2. Periode observasi peramalan dilakukan pada 10 tahun terakhir, yaitu mulai 2008 sampai 2018. Pada penelitian selanjutnya dapat menambahkan periode observasi dari tahun 2000 untuk meningkatkan performa model yang dibuat.
3. Pada penelitian ini, observasi hanya dilakukan pada hari kerja setiap tahunnya. Diharapkan proses observasi pada penelitian selanjutnya dapat dilakukan pada keseluruhan hari dalam satu tahun.
4. Penelitian ini menggunakan aplikasi Matlab untuk meramalkan *close price* indeks harga saham Indonesia. Diharapkan dalam penelitian kedepannya akan menggunakan bahasa pemrograman lain, contohnya *Python* untuk membandingkan kecepatan proses training dan testing.

DAFTAR PUSTAKA

- [1] T. Setia and J. Wijaya, “Faktor-Faktor Yang Mempengaruhi Nilai IHSG Yang Terdaftar Di Bursa Efek Indonesia,” 2015.
- [2] A. A. Adebisi, A. O. Adewumi, and C. K. Ayo, “Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction,” *J. Appl. Math.*, vol. 2014, pp. 1–7, Mar. 2014.
- [3] “Jakarta Composite Index : JKSE Composite Index - Yahoo Finance.” [Online]. Available: <https://finance.yahoo.com/quote/%5EJKSE?ltr=1>. [Accessed: 13-Feb-2018].
- [4] “Foreign Exchange Transaction Rates - Bank Sentral Republik Indonesia.” [Online]. Available: <http://www.bi.go.id/en/moneter/informasi-kurs/transaksi-bi/Default.aspx>. [Accessed: 01-Mar-2018].
- [5] M. Qiu, Y. Song, and F. Akagi, “Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market,” *Chaos, Solitons & Fractals*, vol. 85, pp. 1–7, Apr. 2016.
- [6] N. Ullah, “Impact of Foreign Exchange rate on stock prices,” *IOSR J. Bus. Manag.*, vol. 7, no. 3, pp. 45–51.
- [7] J.-Z. Wang, J.-J. Wang, Z.-G. Zhang, and S.-P. Guo, “Forecasting stock indices with back propagation neural network,” *Expert Syst. Appl.*, vol. 38, no. 11, pp. 14346–14355, Oct. 2011.
- [8] F. A. de Oliveira, C. N. Nobre, and L. E. Zárate, “Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index – Case study of PETR4, Petrobras, Brazil,” *Expert Syst. Appl.*, vol. 40, no. 18, pp. 7596–

7606, Dec. 2013.

- [9] “Manfaat dan Kegunaan IHSG - Kompas.com.” [Online]. Available: <https://ekonomi.kompas.com/read/2013/04/14/02394859/manfaat.dan.kegunaan.ihsg>. [Accessed: 02-Mar-2018].
- [10] “IHSG Hari Ini.” [Online]. Available: <http://ihsg-idx.com/>. [Accessed: 02-Mar-2018].
- [11] F. Ikhsan, “Penerapan Metode Exponential Smoothing Untuk Peramalan Penggunaan Waktu Telepon Di PT.Telkomsel DIVRE3 Surabaya.” .
- [12] P. Goodwin, *Forewarned A Sceptic’s Guide to Prediction*. Biteback Publishing, 2017.
- [13] J. Lin, E. Keogh, S. Lonardi, and B. Chiu, “A symbolic representation of time series, with implications for streaming algorithms,” in *Proceedings of the 8th ACM SIGMOD workshop on Research issues in data mining and knowledge discovery - DMKD ’03*, 2003, p. 2.
- [14] J. Han, M. Kamber, and J. Pei, “Data Mining. Concepts and Techniques, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems),” 2011.
- [15] D. Hunter, Y. Hao, M. S. Pukish, J. Kolbusz, and B. M. Wilamowski, “Selection of Proper Neural Network Sizes and Architectures-A Comparative Study,” 2012.
- [16] A. Blum, *Neural networks in C++ : an object-oriented framework for building connectionist systems*. Wiley, 1992.
- [17] F. Karray, “Introduction Features Fundamentals Madaline Case Study: Binary Classification Using Perceptron Fundamentals of Artificial Neural Networks,” 2009.
- [18] D. A. Bennett, “How can I deal with missing data in my study?,” *Aust. N. Z. J. Public Health*, vol. 25, no. 5, pp. 464–469, Oct. 2001.

BIODATA PENULIS



Penulis bernama lengkap Aldo Chandra Purnomo, dengan panggilan Aldo. Penulis dilahirkan di kota Blora, pada tanggal 27 Agustus 1996. Penulis telah menempuh pendidikan formal di SD Masehi Sion Blora, SMPN 1 Blora, SMAN 1 Blora, dan masuk ke perguruan tinggi Institut Teknologi Sepuluh Nopember Surabaya Departemen Sistem Informasi pada tahun 2014.

Penulis aktif di organisasi eksekutif kampus tingkat fakultas, yaitu Badan Eksekutif Mahasiswa FTIF selama satu periode mulai 2015-2016 sebagai staff dan pada periode 2016-2017 mencari pengalaman di PMK ITS sebagai Kepala Departemen pada Divisi Pemuridan PMK ITS. Penulis juga aktif mencari pengalaman dalam berbagai kepanitiaan pada periode 2014-2015, yaitu diantaranya aktif didalam kepanitiaan ITS Mengajar sebagai staff logistik, menjadi staff sie acara dalam kegiatan BEM Fakultas, dan menjadi kakak pembimbing dalam Manage 2015.

Halaman ini sengaja dikosongkan

LAMPIRAN**Lampiran A – Data Harian *Close price* dan Kurs Jual**

Tanggal	<i>Close price</i>	Kurs Jual
2-Jan-08	2731.51	9,417
3-Jan-08	2715.06	9,460
4-Jan-08	2765.19	9,471
7-Jan-08	2776.41	9,501
8-Jan-08	2785.63	9,502
9-Jan-08	2830.26	9,512
14-Jan-08	2810.37	9,474
15-Jan-08	2730.03	9,478
16-Jan-08	2592.31	9,488
17-Jan-08	2649.28	9,492
18-Jan-08	2611.13	9,524
21-Jan-08	2485.88	9,500
22-Jan-08	2294.52	9,533
23-Jan-08	2476.28	9,450
24-Jan-08	2516.70	9,412
25-Jan-08	2620.49	9,390
28-Jan-08	2582.05	9,394
29-Jan-08	2607.84	9,380
30-Jan-08	2610.36	9,351
31-Jan-08	2627.25	9,337
1-Feb-08	2646.82	9,269
4-Feb-08	2701.63	9,276
5-Feb-08	2704.25	9,273
6-Feb-08	2639.09	9,290

...
...
3-Jan-17	5275.97	13,552
4-Jan-17	5301.18	13,545
5-Jan-17	5325.50	13,437
6-Jan-17	5347.02	13,414
9-Jan-17	5316.36	13,452
10-Jan-17	5309.92	13,387
11-Jan-17	5301.24	13,394
12-Jan-17	5292.75	13,354
13-Jan-17	5272.98	13,375
16-Jan-17	5270.01	13,421
17-Jan-17	5266.94	13,448
18-Jan-17	5294.78	13,395
19-Jan-17	5298.95	13,443
20-Jan-17	5254.31	13,449
23-Jan-17	5250.97	13,439
24-Jan-17	5292.09	13,397
1-Feb-17	5327.16	13,416
2-Feb-17	5353.71	13,441
3-Feb-17	5360.77	13,429
6-Feb-17	5396.00	13,396
7-Feb-17	5381.48	13,389
8-Feb-17	5361.09	13,404
9-Feb-17	5372.08	13,375
10-Feb-17	5371.67	13,385
13-Feb-17	5409.56	13,397
14-Feb-17	5380.67	13,397
2-Jan-18	6339.24	13,616

Lampiran B – Hasil Peramalan *Close price*

Date	Data Aktual	Hasil Peramalan
4-Aug-17	5781	5777
7-Aug-17	5780	5749
8-Aug-17	5755	5811
9-Aug-17	5824	5824
10-Aug-17	5824	5826
11-Aug-17	5825	5766
14-Aug-17	5759	5801
15-Aug-17	5810	5835
16-Aug-17	5837	5892
18-Aug-17	5893	5894
21-Aug-17	5889	5861
22-Aug-17	5858	5880
23-Aug-17	5874	5914
24-Aug-17	5921	5894
25-Aug-17	5888	5915
28-Aug-17	5918	5903
29-Aug-17	5909	5888
30-Aug-17	5883	5873
31-Aug-17	5875	5864
4-Sep-17	5873	5814
5-Sep-17	5812	5830
6-Sep-17	5840	5824
7-Sep-17	5833	5832
8-Sep-17	5835	5857
11-Sep-17	5862	5872
12-Sep-17	5879	5872

B - 2

13-Sep-17	5867	5846
14-Sep-17	5849	5852
15-Sep-17	5859	5872
18-Sep-17	5874	5885
19-Sep-17	5885	5901
20-Sep-17	5903	5907
22-Sep-17	5907	5912
25-Sep-17	5909	5895
26-Sep-17	5891	5864
27-Sep-17	5862	5863
28-Sep-17	5866	5841
29-Sep-17	5845	5901
2-Oct-17	5905	5914
3-Oct-17	5915	5939
4-Oct-17	5931	5951
5-Oct-17	5946	5902
6-Oct-17	5898	5905
9-Oct-17	5896	5915
10-Oct-17	5930	5906
20-Oct-17	5908	5930
23-Oct-17	5939	5950
24-Oct-17	5951	5952
25-Oct-17	5953	6025
26-Oct-17	6029	5996
27-Oct-17	5991	5975
30-Oct-17	5963	5974
31-Oct-17	5977	6006
1-Nov-17	6014	6038
2-Nov-17	6031	6031
3-Nov-17	6036	6040

6-Nov-17	6040	6051
7-Nov-17	6050	6060
8-Nov-17	6061	6049
9-Nov-17	6050	6042
10-Nov-17	6044	6022
27-Nov-17	6067	6065
28-Nov-17	6069	6071
29-Nov-17	6076	6061
30-Nov-17	6057	5952
1-Dec-17	5951	5952
4-Dec-17	5960	5998
5-Dec-17	6019	6000
6-Dec-17	6002	6036
7-Dec-17	6035	6007
8-Dec-17	6014	6031
11-Dec-17	6024	6027
12-Dec-17	6026	6032
13-Dec-17	6033	6055
14-Dec-17	6054	6114
15-Dec-17	6123	6119
18-Dec-17	6110	6134
19-Dec-17	6128	6168
20-Dec-17	6169	6109
21-Dec-17	6101	6183
22-Dec-17	6182	6221
27-Dec-17	6233	6277
28-Dec-17	6270	6314
2-Jan-18	6307	6356