

**PENERAPAN JARINGAN SYARAF TIRUAN *EXTREME LEARNING*
MACHINE DAN *BACKPROPAGATION* UNTUK MEMPREDIKSI HARGA
SAHAM PT BANK MANDIRI (PERSERO) TBK**

(Studi Kasus: Harga Penutupan Saham Harian PT. Bank Mandiri (Persero) Tbk dari
Januari 2019 sampai dengan Januari 2020)



**PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2020**

**PENERAPAN JARINGAN SYARAF TIRUAN *EXTREME LEARNING*
MACHINE DAN *BACKPROPAGATION* UNTUK MEMPREDIKSI HARGA
SAHAM PT BANK MANDIRI (PERSERO) TBK**

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Program Studi
Statistika



Disusun Oleh:

Zulinda

16611046

**PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA**

2020

HALAMAN PERSETUJUAN PEMBIMBING
TUGAS AKHIR

Judul : Penerapan Jaringan Syaraf Tiruan *Extreme Learning Machine*
dan *Backpropagation* untuk Memprediksi Harga Saham PT.
Bank Mandiri (Persero) Tbk

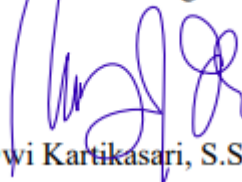
Nama Mahasiswa : Zulinda

Nomor Mahasiswa : 16611046

**TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI UNTUK
DIUJIKAN**

Yogyakarta, 27 April 2020

Pembimbing



(Mujiati Dwi Kartikasari, S.Si., M.Sc.)

HALAMAN PENGESAHAN

TUGAS AKHIR

**PENERAPAN JARINGAN SYARAF TIRUAN *EXTREME LEARNING*
MACHINE DAN *BACKPROPAGATION* UNTUK MEMPREDIKSI HARGA
SAHAM PT BANK MANDIRI (PERSERO) TBK**

(Studi Kasus: Harga Penutupan Saham Harian PT. Bank Mandiri (Persero) Tbk dari
Januari 2019 sampai dengan Januari 2020)

Nama Mahasiswa : Zulinda
Nomor Mahasiswa : 16611046

**TUGAS AKHIR INI TELAH DIUJIKAN
PADA TANGGAL 06 Mei 2020**

Nama Penguji	Tanda Tangan
1. Dr. Techn. Rohmatul Fajriyah, M.Si
2. Dr. Edy Widodo, S.Si., M.Si
3. Mujiati Dwi Kartikasari, S.Si., M.Sc

Mengetahui,
Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Islam Indonesia



Prof. Riyanto, S.Pd., M.Si., Ph.D.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Alhamdulillahirrabbi'l'amin, puji syukur penulis panjatkan atas kehadiran Allah SWT yang telah melimpahkan rahmat, hidayah, dan inayah-Nya berupa keimanan, kesabaran serta keselamatan dalam menyelesaikan tugas akhir ini sehingga dapat terselesaikan. Shalawat serta salam semoga senantiasa tercurahkan kepada Nabi Muhammad SAW selaku tauladan terbaik hingga akhir zaman. Semoga Allah melimpahkan rahmat kepada beliau, serta kepada keluarga, sahabat, tabi'in dan para pengikutnya.

Penulisan tugas akhir ini tersusun sebagai hasil dari proses pembelajaran yang telah penulis dapatkan selama proses pembelajaran di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia, Yogyakarta. Penulisan ini bertujuan untuk memprediksi harga penutupan saham harian pada PT. Bank Mandiri (Persero) Tbk dan melakukan perbandingan antara metode *Extreme Learning Machine* dan metode *Backpropagation*.

Selama penyusunan tugas akhir ini penulis banyak mendapat bimbingan, dukungan, dan bantuan dari berbagai pihak. Untuk itu pada kesempatan ini untuk mengucapkan ucapan terimakasih kepada:

1. Bapak Fathul Wahid, S.T., M.Sc., Ph.D selaku Rektor Universitas Islam Indonesia yang telah memberikan kesempatan kepada penulis untuk melaksanakan studi di Universitas Islam Indonesia.
2. Bapak Prof. Riyanto, S.Pd., M.Si., Ph.D selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia.
3. Bapak Dr. Edy Widodo, S.Si., M.Si. selaku Ketua Jurusan Statistika beserta jajarannya.
4. Ibu Mujiati Dwi Kartikasari, S.Si., M.Sc. selaku dosen pembimbing tugas akhir yang sudah bersedia meluangkan waktu dan telah banyak membantu dalam

memeberikan ilmu, arahan, saran, motivasi serta sangat sabar dalam membimbing penulis selama menyelesaikan tugas akhir ini.

5. Seluruh dosen FMIPA UII yang telah membimbing dan memberikan pengajaran selama kuliah, serta seluruh karyawan FMIPA UII yang membantu dalam proses perkuliahan hingga terselesaikannya tugas akhir ini.
6. Teristimewakan kepada orang tua tersayang Ayah Abu Bakar dan Ibu Zubaidah, yang selalu memberikan doa, memberikan semangat yang luar biasa, dari awal kuliah sampai akhir penyusunan tugas akhir ini. Serta abang dan kakak tercinta Zuherman dan Zuriyah, juga keponakan tersayang Zura, Zizi, Zain dan Zyha terimakasih selalu menjadi penyemangat dan penghibur selama proses perkuliahan sampai menyelesaikan tugas akhir ini.
7. Nong Tegar Harifanza yang selalu memberikan semangat, *support*, selalu ada menemani, memberikan dorongan dan yang selalu mendengar keluh kesah dalam proses penyelesaian tugas akhir ini.
8. Feren Reski Finasty sahabat dari kecil hingga sekarang, yang bersama-sama dalam proses belajar, yang sama-sama mengejar cita-cita dan mimpi. Terimakasih telah menjadi sahabat yang selalu ada.
9. Kom Bongak Shely, Aat, Una, Ewik, terimakasih telah menghiasi masa-masa kuliah dari menjadi mahasiswa baru sampai menjadi mahasiswa semester tua bersama-sama. Saling memberikan semangat, saling mengingatkan, dan saling membantu dari hal-hal kecil. Terimakasih telah berproses bersama dan melukiskan kenangan kuliah yang tak mungkin terlupakan.
10. Teman-teman mahasiswa Anambas-Yogyakarta yang telah menjadi keluarga selama berada ditanah rantauan yang selalu merangkul, memberikan semangat, bersama-sama dalam menuntut ilmu dan mengejar mimpi yang telah diharapkan oleh kedua orang tua.
11. Teman-teman seperjuangan ARTCOST 2016 yang selalu berbagi ilmu, informasi, dan wawasannya.


12. Dan semua pihak yang telah membantu dan tidak bisa penulis sebutkan satu persatu.

Terimakasih kepada semua pihak yang telah memberikan bantuan hingga tugas akhir ini dapat diselesaikan. Penulis menyadari bahwa tugas akhir ini masih jauh dari sempurna, oleh karena itu kritik dan saran yang membangun sangat diperlukan. Demikianlah yang dapat disampaikan, semoga Allah SWT senantiasa melimpahkan rahmat dan ridho-Nya kepada semua pihak yang telah membantu penulis. Serta, penulis berharap semoga penulisan tugas akhir ini dapat bermanfaat bagi semua pihak.

Wassalamu'alaikum Wr. Wb.

Yogyakarta, 27 April 2020

(Zulinda)



DAFTAR ISI

HALAMAN SAMPUL.....	ii
HALAMAN PERSETUJUAN PEMBIMBING.....	iii
HALAMAN PENGESAHAN.....	iv
KATA PENGANTAR.....	v
DAFTAR ISI.....	viii
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
DAFTAR LAMPIRAN.....	xiv
HALAMAN PERNYATAAN.....	xv
INTISARI.....	xvi
<i>ABSTRACT</i>	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Penelitian.....	6
1.5 Manfaat Penelitian.....	6
BAB II TINJAUAN PUSTAKA.....	7
2.1 <i>Extreme Learning Machine</i> (ELM).....	7
2.2 <i>Backpropagation</i>	9
BAB III LANDASAN TEORI.....	11

3.1 Pengertian Saham	11
3.2 Statistika Deskriptif.....	12
3.3 Peramalan (<i>Forecasting</i>)	12
3.4 Analisis Runtun Waktu.....	13
3.5 Pola Data Runtun Waktu.....	14
3.6 Jaringan Syaraf Tiruan	16
3.6.1 Komponen Jaringan Syaraf Tiruan	17
3.6.2 Arsitektur Jaringan.....	18
3.6.3 Fungsi Aktivasi	20
3.7 <i>Extreme Learning Machine</i> (ELM).....	22
3.7.1 Normalisasi Data.....	23
3.7.2 Proses <i>Training</i>	23
3.7.3 Proses <i>Testing</i>	25
3.7.4 Proses Denormalisasi Data	26
3.8 Algoritma Jaringan Syaraf Tiruan <i>Backpropagation</i>	26
3.9 Ukuran Kesalahan Peramalan.....	31
3.9.1 MSE (<i>Mean square error</i>)	31
3.9.2 MAPE (<i>Mean Absolute Percentage Error</i>)	32
BAB IV METODE PENELITIAN	33
4.1 Populasi Penelitian	33
4.2 Jenis dan Sumber Data	33
4.3 Variabel Penelitian	33
4.4 Metode Analisis Data	33

4.5 Tahap Penelitian	34
4.5.1 Tahap penelitian <i>Extreme Learning Machine</i> (ELM).....	34
4.5.2 Tahap penelitian <i>Backpropagation</i>	36
BAB V PEMBAHASAN	38
5.1 Analisis Deskriptif.....	38
5.2 Metode <i>Extreme Learning Machine</i> (ELM).....	39
5.2.1 Pemeriksaan Data <i>Missing</i>	39
5.2.2 Normalisasi Data.....	39
5.2.3 Pembagian Data <i>Training</i> dan <i>Data Testing</i>	39
5.2.4 Arsitektur Jaringan <i>Extreme Learning Machine</i>	40
5.2.5 Hasil Prediksi.....	42
5.3 Metode <i>Backpropagation</i>	43
5.3.1 Pemeriksaan Data <i>Missing</i>	43
5.3.2 Normalisasi Data.....	44
5.3.3 Pembagian Data <i>Training</i> dan <i>Data Testing</i>	44
5.3.4 Arsitektur Jaringan Syaraf Tiruan <i>Backpropagation</i>	45
5.3.5 Inisialisasi Bobot.....	47
5.3.6 Pelatihan Model <i>Backpropagation</i>	48
5.3.7 Hasil Prediksi.....	53
5.4 Perbandingan Metode ELM dan <i>Backpropagation</i>	54
4.4.1 MAPE Prediksi Metode <i>Extreme Learning Machine</i>	54
4.4.2 MAPE Prediksi Metode <i>Backpropagation</i>	55
BAB VI PENUTUP	57

6.1 Kesimpulan.....	57
6.2 Saran.....	58
DAFTAR PUSTAKA	59
LAMPIRAN.....	64



DAFTAR TABEL

Tabel 3. 1 Interpretasi Nilai MAPE	32
Tabel 5. 1 Pola <i>Input</i> Data <i>Training</i>	39
Tabel 5. 2 Pembagian Data <i>Training</i> dan <i>Testing</i>	40
Tabel 5. 3 Uji Coba Jumlah <i>Neuron</i> Pada <i>Hidden Layer</i>	41
Tabel 5. 4 Data Aktual Dan Prediksi Metode <i>Extreme Learning Machine</i>	43
Tabel 5. 5 Hasil Pemeriksaan Data <i>Missing</i>	44
Tabel 5. 6 Pembagian Data <i>Training</i> dan <i>Testing</i>	45
Tabel 5. 7 Uji Coba Jumlah <i>Neuron</i> Pada <i>Hidden Layer</i>	46
Tabel 5. 8 Bobot Awal <i>Hidden Layer</i>	47
Tabel 5. 9 Bobot Awal <i>Hidden Layer</i> ke <i>Output</i>	47
Tabel 5. 10 Sinyal <i>Input</i> dari <i>Input Layer</i> ke <i>Hidden Layer</i>	48
Tabel 5. 11 Sinyal <i>Output</i> di <i>Hidden Layer</i>	49
Tabel 5. 12 Sinyal <i>Input</i> dari <i>Hidden Layer</i> ke <i>Output Layer</i>	49
Tabel 5. 13 Sinyal <i>Output</i> di <i>Output Layer</i>	49
Tabel 5. 14 Koreksi Bobot dan Bias di <i>Hidden layer</i> Terhadap <i>Output Layer</i>	50
Tabel 5. 15 Faktor Kesalahan di Unit Tersembunyi.....	50
Tabel 5. 16 Faktor Kesalahan di Unit Tersembunyi.....	51
Tabel 5. 17 Koreksi Bobot dan Bias di <i>Input Layer</i> Terhadap <i>Hidden layer</i>	51
Tabel 5. 18 Bobot dan Bias Akhir pada <i>Input Layer</i> Terhadap <i>Hidden layer</i>	52
Tabel 5. 19 Bobot dan Bias Akhir pada <i>Hidden layer</i> Terhadap <i>Output Layer</i>	52
Tabel 5. 20 Data Aktual Dan Prediksi Metode <i>Backpropagation</i>	53
Tabel 5. 21 Hasil Nilai MAPE Metode ELM.....	55
Tabel 5. 22 Hasil Nilai MAPE Metode <i>Backpropagation</i>	55
Tabel 5. 23 Hasil Perbandingan Metode	56

DAFTAR GAMBAR

Gambar 1. 1 BMRI Harga Saham PT. Bank Mandiri (Persero) Tbk	3
Gambar 3. 1 Pola Data Siklis.....	15
Gambar 3. 2 Pola Data Musiman.....	15
Gambar 3. 3 Pola Data Horizontal.....	16
Gambar 3. 4 Pola Data Trend	16
Gambar 3. 5 Susunan Syaraf Manusia.....	17
Gambar 3. 6 Jaringan Layer Tunggal	18
Gambar 3. 7 Jaringan Layer Jamak	19
Gambar 3. 8 Jaringan <i>Reccurent</i>	20
Gambar 3. 9 Fungsi Aktivasi Sigmoid Bipolar	21
Gambar 3. 10 Fungsi Aktivasi Sigmoid Bipolar	21
Gambar 3. 11 Struktur Metode ELM.....	22
Gambar 4. 1 Diagram ELM.....	34
Gambar 4. 2 Diagram Alir <i>Backpropagation</i>	36
Gambar 5. 1 Harga Penutupan Saham PT. Bank Mandiri (Persero) Tbk.....	38
Gambar 5. 2 Arsitektur Jaringan Saham PT. Bank Mandiri (Persero) Tbk	40
Gambar 5. 3 Plot Data Asli dan Data Prediksi Metode ELM	42
Gambar 5. 4 Rancangan Arsitektur Jaringan.....	46
Gambar 5. 5 Plot Data Asli dan Data Prediksi Metode <i>Backpropagation</i>	53

DAFTAR LAMPIRAN

Lampiran 1 Data Saham PT. Bank Mandiri (Persero) Tbk.....	64
Lampiran 2 Hasil <i>Training</i> Metode <i>Extreme Learning Machine</i>	67
Lampiran 3 Hasil <i>Training</i> Metode <i>Backpropagation</i>	74
Lampiran 4 <i>Syntax</i> Program R Metode <i>Extreme Learning Machine</i>	81
Lampiran 5 <i>Syntax</i> Program R Metode <i>Backpropagation</i>	82



HALAMAN PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan di suatu perguruan tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

Yogyakarta, 27 April 2020



(Zulinda)

PENERAPAN JARINGAN SYARAF TIRUAN *EXTREME LEARNING MACHINE* DAN *BACKPROPAGATION* UNTUK MEMPREDIKSI HARGA SAHAM PT BANK MANDIRI (PERSERO) TBK

(Studi Kasus: Harga Penutupan Saham Harian PT. Bank Mandiri (Persero) Tbk Dari Januari 2019 sampai dengan Januari 2020)

Zulinda

Program Studi Statistika, Fakultas MIPA

Universitas Islam Indonesia

INTISARI

Saham telah menjadi suatu alat investasi yang banyak diminati. Di kalangan masyarakat yang mempunyai dana yang lebih maka investasi saham adalah salah satu pilihan terbaik untuk berinvestasi sehingga mendapatkan keuntungan bagi pemilik atau pembelinya. Kondisi saham yang terus mengalami fluktuasi setiap harinya akan membuat para investor yang sudah menanamkan investasi juga perlu memperhatikan dan mempelajari terlebih dahulu data masa lalu perusahaan. Hal tersebut untuk digunakan investor dalam mengetahui prospek kedepannya dari harga saham yang ada disuatu perusahaan. Oleh karena itu, peramalan harga saham salah satu langkah untuk berinvestasi yang baik. Dalam penelitian ini dilakukan prediksi harga saham menggunakan metode *Extreme Learning Machine* dan *Backpropagation*. Hasil perbandingan nilai *Mean Absolute Percentage Error* pada kedua metode didapatkan metode *Extreme Learning Machine* nilai MAPE pada data *training* sebesar 1.243%, sedangkan pada metode *Backpropagation* nilai MAPE pada data *training* sebesar 1.198% dimana hasil menunjukkan bahwa presentase metode *Backpropagation* pada data *training* tingkat kesalahannya lebih kecil daripada metode ELM. Pada metode *Extreme Learning Machine* nilai MAPE pada data *testing* sebesar 1.192%, sedangkan pada metode *Backpropagation* nilai MAPE pada data *testing* sebesar 1.627% dimana hasil menunjukkan bahwa presentase metode ELM pada data *testing* tingkat kesalahannya lebih kecil daripada metode *Backpropagation*.

Kata Kunci: Data Saham, Prediksi, *Extreme Learning Machine*, *Backpropagation*

**APPLICATION OF ARTIFICIAL NETWORK EXTREME LEARNING
MACHINE AND ARTIFICIAL NETWORK BACKPROPAGATION FOR
PREDICTING STOCK PRICE OF PT BANK MANDIRI (PERSERO) TBK**

*(Case Study: Daily Bank Closing Price of PT. Bank Mandiri (Persero) Tbk from
January 2019 to January 2020)*

Zulinda

Department of Statistics, Faculty of Mathematics and Science

Islamic University of Indonesia

ABSTRACT

Stocks have become a popular investment tool. Among the people who have more funds then stock investment is one of the best choices for invest so that it benefits the owner or buyer. Stock condition which continues to fluctuate every day will make investors who already are investing also need to pay attention and study in advance the past data company. This is to be used by investors in knowing future prospects from the price of shares in a company. Therefore, forecasting stock prices is one steps to a good investment. In this research stock price predictions are performed using the Extreme Learning Machine and Backpropagation methods. Value comparison results Mean Absolute Percentage Error in both methods is obtained by the Extreme Learning method Machine MAPE value in the training data is 1,243%, while in the method Backpropagation MAPE value in the training data is 1,198% where the results show that the percentage of Backpropagation methods in the training data is smaller than the ELM method. In the Extreme Learning Machine method the MAPE value in the testing data amounting to 1.192%, while the method of Backpropagation value of MAPE in the data testing for 1.627% where the results show that the percentage of the ELM method at the data testing level the error is smaller that the Backpropagation method

Keywords: *Stock Data, Prediction, Extreme Learning Machine, Backpropagation*

BAB I

PENDAHULUAN

1.1 Latar Belakang

Di Indonesia bahkan di dunia, saham telah menjadi suatu alat investasi yang banyak diminati. Di kalangan masyarakat yang mempunyai dana yang lebih maka investasi saham adalah salah satu pilihan terbaik untuk berinvestasi sehingga mendapatkan keuntungan bagi pemilik atau pembelinya. Saham merupakan instrument pasar modal yang memberikan tingkat keuntungan yang menarik sehingga banyak diminati investor (Fahmi, 2012).

Seseorang atau pihak (badan usaha) tertentu yang membeli saham berarti otomatis orang atau pihak tersebut membeli sebagian kepemilikan atas perusahaan yang dibeli. Seseorang atau pihak (badan usaha) tersebut juga memiliki klaim atas pendapatan perusahaan, klaim atas aset perusahaan, dan bahkan berhak hadir dalam rapat umum pemegang saham (RUPS) (Danareksaonline, 2014). Investasi saham adalah suatu yang memberikan keuntungan yang sangat tinggi. Disisi lain harga saham yang berubah-ubah setiap waktu dan ada beberapa faktor menjadikan saham sebagai instrument investasi yang beresiko tinggi pula.

Dua tipe investasi saham yang sering dilakukan oleh seseorang investor adalah investasi jangka pendek dan investasi jangka panjang. Investasi jangka pendek melibatkan transaksi jual beli suatu saham dalam kurun waktu kurang dari satu tahun sedangkan, investasi jangka panjang berada dalam kurva waktu lebih dari satu tahun. Kedua tipe investasi ini memiliki permasalahan yang sama, yaitu sulitnya meramal harga saham suatu perusahaan. Apabila seorang investor baru tidak cermat dalam mengamati pergerakan harga saham, investasi saham justru akan menimbulkan kerugian. (Pratama, Adikara, & Adinugroho, 2018)

Sebagai investor tentu membutuhkan produk dan dukungan Bank yang menyediakan layanan yang cepat, mudah, praktis, dan menguntungkan. Bank Mandiri

juga sudah bekerja sama dengan lebih dari 80 perusahaan sekuritas. Bagi generasi millennial kesadaran untuk menabung sudah lebih baik dari generasi sebelumnya. Sebagian besar masyarakat pasti mempunyai simpanan dalam satu bank, bahkan lebih dari satu bank. Dan bagi yang ingin serius untuk mengembangkan uang yang dimiliki, hal yang tepat adalah menginvestasikan uang di pasar saham untuk bekerja lebih efektif. Banyak pilihan investasi saham perbankan yang bisa dipilih salah satunya adalah di Bank Mandiri, dilihat dari historis harga saham mandiri memang menjanjikan untuk berinvestasi.

PT. Bank Mandiri (Persero) Tbk (BMRI) merupakan salah satu bank plat merah dengan aset terbesar. PT. Bank Mandiri (Persero) Tbk (BMRI) juga sudah lama berkencimpung di dunia saham, sahamnya termasuk salah satu yang likuid ditransaksikan di Bursa Efek Indonesia (BEI) sehingga harga saham Mandiri makin meningkat. Tahun 2019 harga saham Mandiri terpantau di Rp.7,375/saham, pada 23 Januari 2009 harga saham tercatat pada level Rp.874/saham. Jika dihitung dari selisih kenaikan harga saham, terjadi kenaikan sebesar 742.86%, dimana kenaikan harga cukup signifikan (Utami, 2019)

PT. Bank Mandiri (Persero) Tbk yang menurut data statistik perbankan yang dibuat oleh Bank Indonesia dari tahun ke tahun hampir mengalami peningkatan yang signifikan. Ini menunjukkan bahwa PT. Bank Mandiri (Persero) Tbk mempunyai pengelolaan keuangan yang baik dan sehat. Berikut merupakan data harga saham PT. Bank Mandiri (Persero) Tbk.



Gambar 1.1 BMRI Harga Saham PT. Bank Mandiri (Persero) Tbk
(Sumber: Investing.com)

Gambar 1.1 menunjukkan harga saham PT. Bank Mandiri (Persero) Tbk cenderung menguat setiap tahunnya. Kondisi seperti ini dapat mempengaruhi tingkat kepercayaan dari calon-calon investor pada perusahaan karena jika tingkat pengembalian saham bank Mandiri mengalami trend positif, maka akan menjadi daya tarik dari investor untuk menanamkan modalnya.

Kondisi saham yang terus mengalami fluktuasi setiap harinya akan membuat para investor yang sudah menanamkan investasi juga perlu memperhatikan dan mempelajari terlebih dahulu data masa lalu perusahaan. Hal tersebut untuk digunakan investor dalam mengetahui prospek kedepannya dari harga saham yang ada disuatu perusahaan. Oleh karena itu, peramalan harga saham salah satu langkah untuk berinvestasi yang baik.

Peramalan terhadap harga saham sangat bermanfaat untuk melihat prospek investasi saham suatu perusahaan pada masa yang akan datang. Peramalan ini juga diharapkan bisa mengurangi resiko bagi investor dalam berinvestasi pada suatu perusahaan agar terhindar dari kerugian (Riyanto, 2017). Seiring perkembangannya ilmu pengetahuan, para peneliti di bidang *Artificial Intelligence* berusaha mengembangkan metode untuk memprediksi pergerakan saham. Dari sekian banyak metode *Artificial Intelligence* yang digunakan untuk memprediksi, metode yang banyak digunakan oleh peneliti adalah jaringan syaraf tiruan karena sifatnya yang

bebas estimator serta mampu menghasilkan *output* yang mampu mendekati nilai sebenarnya (Agustina, 2010).

Jaringan Syaraf Tiruan (JST) atau yang dikenal dengan *Artificial Neural Network* (ANN) adalah sistem pemroses informasi yang dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologis pada manusia. JST terdiri atas elemen pemroses bernama *neuron* yang dihubungkan dengan elemen pemroses lain oleh suatu aturan dan bobot. Seiring perkembangan zaman, aplikasi JST banyak dimanfaatkan di bidang ekonomi terutama yang berhubungan dengan peramalan data. JST dapat digunakan untuk meramalkan apa yang terjadi dimasa yang akan datang berdasarkan pola yang ada di masa lampau (Siang, 2009). Banyak metode dalam JST yang telah dikemukakan untuk melakukan peramalan, antara lain adalah metode yang dapat digunakan peramalan adalah *Extreme Learning Machine* (ELM) dan *Backpropagation*. *Extreme Learning Machine* merupakan JST *feedforward* dengan *single hidden layer* atau biasa disebut dengan *Single Hidden Layer Feedforward Neural Networks* (SLFNs). Sementara, *Backpropagation* atau algoritma propagasi balik adalah sebuah metode sistematis untuk pelatihan JST *Multi-Layer Feedforwrd Networks*.

Extreme Learning Machine ini merupakan metode pembelajaran baru dari Jaringan Saraf Tiruan. ELM merupakan metode pengembangan dari jaringan 3 saraf tiruan *feedforward* sederhana dengan menggunakan satu *hidden layer* atau biasa dikenal dengan *Single Hidden Layer Feedforward Neural Network* (SLFNs). Jaringan *feedforward* menggunakan parameter-parameter yang ditentukan secara manual seperti *input weight* dan bias. *Input weight* dan bias ini dibangkitkan secara acak dalam suatu rentang tertentu. Dengan nilai yang di acak tersebut, bisa menghindari prediksi yang tidak stabil (Saputri & Ekojono, 2018).

Backpropagation adalah algoritma pembelajaran untuk memperkecil tingkat *error* dengan cara menyesuaikan bobotnya berdasarkan perbedaan *output* dan target yang diinginkan *Backpropagation* juga merupakan sebuah metode sistematis untuk

pelatihan multilayer JTS. *Backpropagation* dikatakan sebagai algoritma pelatihan multilayer karena *Backpropagation* memiliki tiga *layer* dalam poses pelatihnnya, yaitu *input layer*, *hidden layer* dan *output layer* (Ginanto, 2012). Algoritma propagasi balik dapat digunakan untuk menyelesaikan berbagai masalah, seperti klasifikasi, optimasi, estimasi, evaluasi, kompresi, peramalan, sistem kontrol, sistem pendeteksian kecurangan, dan sebagainya (Suyanto, 2011).

Berdasarkan latar belakang maka dapat dilakukan penelitian untuk mengetahui harga prediksi saham untuk para investor yang akan berencana untuk memulai investasi di bidang saham. Metode yang digunakan adalah *Extreme Learning Machine* dan metode *Backpropagation*. Hasil dari kedua metode tersebut akan dibandingkan untuk memperoleh hasil prediksi yang paling tepat.

1.2 Rumusan Masalah

Berdasarkan permasalahan yang sudah dijelaskan sebelumnya dilatar belakang, maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana gambaran umum saham harian PT. Bank Mandiri (Persero) Tbk pada periode 14 Januari 2019 sampai dengan 13 Januari 2020?
2. Bagaimana hasil prediksi menggunakan data saham harian periode 14 Januari 2019 sampai dengan 13 Januari 2020 dengan metode *Extreme Learning Machine* dan *Backpropagation*?
3. Bagaimana hasil perbandingan metode *Extreme Learning Machine* jika dibandingkan dengan *Backpropagation*, dimana tingkat kesalahan diukur menggunakan MAPE (*Mean Absolute Percentage Error*)?

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah:

1. Data yang digunakan pada penelitian ini adalah data saham harian PT. Bank Mandiri (Persero) Tbk pada periode 14 Januari 2019 sampai dengan 13 Januari 2020.

2. Variabel yang digunakan adalah variable (*close*) atau harga peutup saham.
3. Metode analisis yang digunakan adalah metode *Extreme Learning Machine* dan *Backpropagation*.
4. Perangkat lunak yang digunakan dalam penelitian ini adalah R-3.6.1 dan *Microsoft Excel* 2016.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui gambaran umum saham harian PT. Bank Mandiri (Persero) Tbk pada periode 14 Januari 2019 sampai dengan 13 Januari 2020.
2. Mengetahui hasil prediksi menggunakan data saham harian periode 14 Januari 2019 sampai dengan 13 Januari 2020 dengan metode *Extreme Learning Machine* dan *Backpropagation*.
3. Mengetahui hasil perbandingan menggunakan metode *Extreme Learning Machine* jika dibandingkan dengan *Backpropagation*, dimana tingkat kesalahan diukur menggunakan MAPE (*Mean Absolute Percentage Error*).

1.5 Manfaat Penelitian

Adapun manfaat penelitian ini adalah:

1. Menambah dan memperkaya pengetahuan bagi penulis dan mahasiswa pada umumnya tentang pengembangan dan aplikasi metode *Extreme Learning Machine* dan *Backpropagation* dalam memprediksi harga saham PT. Bank Mandiri (Persero) Tbk.
2. Memberikan informasi yang berguna dan hasil prediksi dapat digunakan sebagai bahan kajian bagi pelaku pasar atau investor di pasar modal PT. Bank Mandiri (Persero) Tbk terkait dalam mengantisipasi atau mengambil suatu tindakan bisnis.
3. Dapat digunakan untuk referensi untuk penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

Pada penelitian ini, penulis menggunakan beberapa penelitian terdahulu untuk dijadikan referensi dan acuan dalam menulis dan melakukan penelitian. Berikut merupakan beberapa penelitian sebelumnya tentang metode *Extreme Learning Machine* dan *Backpropagation* yang telah dilakukan penelitian sebelumnya:

2.1 *Extreme Learning Machine* (ELM)

Menurut penelitian Yasinta Amalia Sanudin dan Jaka Nugraha dari Program Studi Statistika, Fakultas MIPA, Universitas Islam Indonesia. Dengan judul penelitian yaitu “Penerapan Metode *Extreme Learning Machine* Untuk Meramalkan Wisatawan Mancanegara Di Sulawesi Utara” dimana penelitian ini membandingkan 2 data wisata yaitu data pada tahun 2004-2015 dan tahun 2004-2018. Hasil dari pengujian yang dilakukan, menggunakan 100 *hidden layer* didapatkan hasil dari data 2004-2015 memiliki nilai MAPE, MAE, dan MSE lebih kecil dibandingkan data tahun 2004-2018. Menghasilkan data wisata mancanegara selama 12 periode kedepan dari bulan Januari sampai dengan bulan Desember 2019 (Sanudin & Nugraha, 2019).

Pada penelitian Ayustina Giusti, Agus Wahyu Widodo, dan Sigit Adinugroho dari Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya pada tahun 2018. Judul penelitian “Prediksi Penjualan Mi Menggunakan Metode *Extreme Learning Machine* (ELM) di Kober Mie Setan Cabang Soekarno Hatta” menyatakan bahwa metode ELM ini memiliki kelebihan dalam *learning speed* dan tingkat *error* yang kecil. Dari pengujian yang telah dilakukan diketahui perbedaan penggunaan fitur data dalam penelitian ini menghasilkan tingkat *error* terkecil yaitu sebesar 0.0171 dengan menggunakan fitur data historis dan fitur data sisa penjualan (Giusti, Widodo, & Adinugroho, 2018).

Johan Saputra dengan penelitiannya yang berjudul “Perbandingan Metode *Fuzzy Time Series Markov Chain* Dan *Extreme Learning Machine* Pada Peramalan Data Penumpang Pesawat Manca-negara Di Bandara Soekarno-Hatta Dan Ngurah-Rai”. Dalam penelitian ini bertujuan untuk memprediksi kedatangan penumpang mancanegara ke Indonesia dan membandingkan antar dua metode memiliki nilai kesalahan yang lebih kecil. Dari hasil penelitian didapatkan metode FTS-MC memiliki nilai kesalahan yang lebih kecil dibandingkan dengan metode ELM dilihat dari hasil nilai MAPE, tetapi setelah ditambahkan data terbaru yaitu data Januari 2019 nilai peramalan dengan metode ELM lebih akurat, sehingga metode ELM lebih tepat digunakan untuk meramalkan jumlah-jumlah penumpang mancanegara (Saputra, 2019).

Selanjutnya penelitian yang disusun dari Ervina Aprilia Saputri dan Ekojono, dengan judul penelitian “Prediksi Volume Impor Beras Nasional Menggunakan Jaringan Syaraf Tiruan Metode ELM (*Extreme Learning Machine*)” dengan menghasilkan tingkat *error* tekecil dengan jumlah *neuron* 7 dan didapatkan hasil MSE sebesar 0.0079. Pembagian data pada penelitian ini adalah data *testing* sebesar 80% dengan banyak data 37 dan data *training* sebesar 20% dengan banyak data 9 dari keseluruhan data yaitu 46 data. Pada penelitian ini juga menyatakan bahwa metode ELM baik digunakan dalam prediksi impor beras nasional (Saputri & Ekojono, 2018).

Penelitian berikutnya berjudul “Peramalan Harga Saham Menggunakan Metode *Extreme Learning Machine* (ELM) Studi Kasus Saham Bank Mandiri” oleh Muhammad Iqbal Pratama, Putra Pandu Adikara, dan Sigit Adinugrogo dari Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya. Hasil yang didapatkan dari penelitian ini adalah nilai *Mean Absolute Percentage Error* (MAPE) terendah yaitu sebesar 1,012% dengan menggunakan fungsi aktivasi *sigmoid*, dengan jumlah *neuron* pada *hidden layer* sebanyak 4 dengan data yang digunakan adalah data saham harian Bank Mandiri dari tanggal 16 Maret sampai dengan 29 Desember 2017 (Pratama, Adikara, & Adinugroho, 2018).

2.2 *Backpropagation*

Penelitian Wisnu Hendro Martono, Dian Hartanti dari Program Studi Teknik Informatika STT-PLN pada tahun 2015 dengan judul penelitian “Penggunaan Jaringan Syaraf Tiruan Dengan Metode *Backpropagation* Dalam Memprediksi Indeks Harga Saham Gabungan (IHSG)”. Data yang digunakan pada penelitian ini adalah 7 perusahaan yang sangat mempengaruhi besarnya Indeks Harga Saham Gabungan yaitu PT. Astra International Indonesia, PT. HM Sampurna, PT. Unilever Indonesia, PT. Telkom Indonesia, PT. United Tractor, PT. Gudang Garam, dan PT Perusahaan Gas Negara. Hasil yang diperoleh pada penelitian ini adalah nilai MSE yang didapatkan adalah 3,636604 setelah bobot dan bias dioptimasi pada saat pelatihan dengan iterasi sebanyak 50 kali dihasilkan nilai MSE sebesar 0,0922114. Pada saat bobot dan bias yang telah dioptimasi digunakan pada jaringan syaraf tiruan untuk meramalkan nilai IHSG pada periode mendatang, nilai MSE yang didapatkan adalah 0,0348015 (Martono & Hartanti, 2015).

Siti Amiroch dengan judul penelitian “Prediksi Harga Saham Menggunakan Jaringan Syaraf Tiruan *Backpropagation*” dalam penelitian ini dilakukan prediksi menggunakan jaringan syaraf tiruan dalam bidang petroleum, chemical, Ilogistik, pabrikan dan batubaara yaitu memprediksi harga saham penutupan (*Close*) pada PT AKR Corporindo Tbk (AKRA Corporindo). Data yang digunakan dalam penelitian ini sebanyak 120 data, data *training* sebanyak 24 data, dan *testing* sebanyak 5 data. Dari hasil penelitian data saham AKRA diperoleh hasil prediksi saham yang mendekati harga sesungguhnya dengan nilai MSE yang sangat kecil dan hasil *training* yang sangat bagus (Amiroch, 2015).

Penelitian yang dilakukan oleh (Nur'afifah, 2011) dengan judul penelitian “Analisis Metode *Backpropagation* Untuk Memprediksi Indeks Harga Saham Pada Kelompok Indeks Bisnis-27”. Dari penelitian ini adalah untuk mengetahui pola-pola pada indikator teknikal yang mempengaruhi penurunan atau kenaikan indeks saham, dengan melihat data-data saham sebelumnya. Data yang digunakan dalam penelitian ini

dari periode Januari 2009 sampai dengan Desember 2010, dengan data pelatihan sebanyak 369 dan data pengujian sebanyak 100 data. Hasil yang diperoleh dari penelitian ini adalah peramalan harga saham untuk hari berikutnya (1 Januari 2011) adalah 332.20 lebih rendah dari harga sebelumnya 20 Desember 2010 yaitu 322.29 dengan selisih 0.09, dengan nilai *Mean square error* (MSE) sebesar 0.00476 pada iterasi ke 20848.

Pada penelitian Ita Qorry Aina dengan judul penelitian “Implementasi *Artificial Neural Network* (ANN) Dengan Algoritma *Backpropagation* untuk Memprediksi Volume Penjualan Di Bukalapak” dalam penelitian ini menggunakan studi kasus dari aksesoris computer di *marketplace* Bukalapak. Diperoleh 3 jenis kategori aksesoris computer yang dianalisis yaitu *mouse*, *speaker & sound*, dan tas & case. Data yang diperoleh dengan cara *scraping* yang dilakukan dari tanggal 10 Februari 2018 hingga 13 Februari 2018. Hasil rancangan arsitektur yang diperoleh yaitu 3 layer yang meliputi 7 *neuron input layer*, 3 *neuron* pada *hidden layer*, dan 1 *neuron* pada *output layer*. Tingkat akurasi yang dihasilkan dalam penelitian ini adalah sebesar 98.99% (Aina, 2018).

Penelitian yang berjudul “Analisis Klasifikasi Genre Musik Pop dan Klasik pada Layanan *Streaming* Musik Spotify Menggunakan *Artificial Neural Network* (ANN)” oleh (Supriyadi, 2018). Dalam penelitian ini data *input* yang digunakan adalah *acousticness*, *danceability*, *energy*, *loudness*, *speechiness*, *tempo* dan *valence* kemudian *output* nya adalah genre music pop dan klasik. Arsitektur jaringan yang diperoleh pada penelitian ini adalah 7 *neuron input*, 1 *hidden layer* dengan 4 *neuron* dan 1 *output*. Hasil dari nilai akurasi pada penelitian ini dari pengujian diperoleh sebesar 99.5%.

Perbedaan penelitian ini dengan penelitian sebelumnya adalah periode dari sampel, dimana penelitian ini menggunakan periode 14 Januari 2019 sampai dengan 13 Januari 2020 dan metode yang digunakan adalah perbandingan antara metode *Extreme Learning Machine* dan metode *Backpropagation*.

BAB III

LANDASAN TEORI

Dalam penulisan ini, sangat diperlukan definisi dan informasi yang diperlukan guna memperdalam materi dan mempermudah dalam pembuatan penulisan, diantaranya adalah sebagai berikut:

3.1 Pengertian Saham

Menurut (Situmorang, Mahardhika, & Listiyarini, 2010), saham adalah surat berharga (efek) yang berbentuk sertifikat guna menunjukkan bukti kepemilikan suatu perusahaan. Semakin banyak saham yang dimiliki oleh seseorang di suatu perusahaan, berarti jumlah uang yang diberikan ke perusahaan itu juga semakin besar, demikian juga pengusaha orang tersebut dalam perusahaan itu semakin tinggi.

Menurut (Fahmi, 2012), saham merupakan instrument pasar modal yang memberikan tingkat keuntungan paling menarik sehingga banyak yang diminati. Saham merupakan sebuah kertas yang tercantum nama perusahaan, nilai nominal, dan tercantum hak dan kewajiban bagi pemegangnya.

Kemudian menurut (Darmadji & Fakhrudin, 2012), tanda kepemilikan seseorang atau badan terhadap suatu perusahaan disebut saham (*stock*). Saham memiliki wujud berupa selembar kertas yang berisi informasi bahwa kepemilikan kertas tersebut merupakan pemilik perusahaan yang menerbitkannya.

Hak pemilik saham dibagi menjadi 2 jenis diantaranya adalah saham biasa dan saham preferen. Perbedaan dari kedua jenis saham tersebut terletak pada keuntungan yang diperoleh. Saham bisa mendapatkan keuntungan sesuai dengan hak bagian yang diambil dalam perusahaan berdasarkan hak perusahaan sedangkan, saham preferen mempunyai hak atas perusahaan lebih besar dibandingkan dengan hak yang didapat saham biasa (Mudjiyono, 2012).

3.2 Statistika Deskriptif

Statistika deskriptif adalah metode yang berkaitan dengan pengumpulan dan penyajian suatu gugus data sehingga memberikan informasi yang berguna. Ukuran-ukuran statistik yang digunakan untuk mendeskripsikan suatu gugus data pada penelitian ini antara lain *mean* (rata-rata), nilai maksimum, dan minimum. *Mean* atau nilai tengah adalah suatu ukuran pusat data bila data itu diurutkan dari yang terkecil sampai yang terbesar atau sebaliknya dengan tujuan untuk mengukur nilai rata-rata data tersebut. *Varians* sampel yang dinotasikan sebagai S^2 adalah ukuran penyebaran data yang mengukur rata-rata kuadrat jarak seluruh titik pengamatan dari nilai tengah. Nilai maksimum adalah nilai pengamatan tertinggi dari segugus data sedangkan, nilai minimum adalah nilai pengamatan terendah dari segugus data yang ada (Walpole, dkk, 2011)

Penelitian deskriptif adalah metode penelitian yang digunakan untuk menemukan pengetahuan yang seluas-luasnya terhadap objek penelitian pada suatu masa tertentu. Kumpulan data yang diperoleh data statistika deskriptif akan tersaji dengan ringkas dan rapi serta dapat memberikan informasi inti dari kesimpulan data yang ada. Informasi yang dapat diperoleh dari statistika deskriptif ini antara lain ukuran pemusatan data, ukuran penyebaran data, serta kecendrungan suatu gugus data (Walpole & Myers, 1995).

3.3 Peramalan (*Forecasting*)

Peramalan adalah perkiraan atas suatu kejadian atau situasi di masa mendatang, sehingga peramalan penjualan merupakan suatu usaha untuk memperkirakan tingkat penjualan yang akan dicapai perusahaan pada waktu mendatang (Asri, 1986).

Peramalan adalah tentang meramalkan masa depan seakurat mungkin, mengingat semua informasi yang tersedia, termasuk data historis dan pengetahuan tentang semua peristiwa di masa depan yang mungkin berdampak pada perkiraan tersebut. Peramalan harus menjadi bagian integral dari kegiatan pengambilan

keputusan manajemen, karena dapat memainkan peran penting dalam banyak bidang perusahaan. Organisasi modern membutuhkan perkiraan jangka pendek, jangka menengah, dan jangka panjang, tergantung pada aplikasi spesifik (Hyndman & Athanasopoulos, 2018). Peramalan berdasarkan horizontal waktu dicakup diklasifikasikan menjadi 3 kategori, antara lain (Heizer & Render, 2006) :

1. Peramalan jangka pendek, peramalan ini mencakup jangka waktu hingga 12 bulan tetapi umumnya kurang dari tiga bulan.
2. Peramalan jangka menengah, peramalan ini pada umumnya mencakup waktu hingga 3 bulan hingga tiga tahun.
3. Peramalan jangka panjang umumnya peramalan ini untuk perencanaan 3 tahun atau lebih.

Pada dasarnya pendekatan peramalan dapat diklasifikasi menjadi dua pendekatan, yaitu (Makridakis, Wheelwright, & McGee, 1999) :

1. Peramalan Kualitatif

Peramalan kualitatif adalah peramalan yang didasarkan atas pendapat suatu pihak dan datanya tidak dapat direpresentasikan secara tegas menjadi suatu angka atau nilai. Hasil peramalan yang dibuat sangat bergantung pada orang yang menyusun. Hal ini penting karena hasil peramalan tersebut ditentukan berdasarkan pemikiran yang intuisi, pendapat dan pengetahuan serta pengalaman penyusunannya.

2. Peramalan Kuantitatif

Peramalan kuantitatif adalah peramalan yang didasarkan atas data kuantitatif masa lalu dan dapat dibuat dalam bentuk angka yang biasa disebut sebagai data *time series* (Jumingan, 2009)

3.4 Analisis Runtun Waktu

Data runtun waktu (*time series*) adalah jenis data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu, Model yang digunakan untuk

memodelkan tipe ini adalah model-model *time series* (Rosadi, 2006). Analisis *time series* bertujuan untuk menemukan pola variasi masa lalu yang digunakan untuk memperkirakan nilai masa depan dan memberikan bantuan dalam manajemen operasi dalam membuat perencanaan (Winarno, 2007). Adapun beberapa manfaat dari analisis *time series* adalah sebagai berikut:


1. Analisis *time series* dapat membantu mempelajari data masa lampau, sehingga dipelajari faktor-faktor penyebab perubahan di masa lampau yang selanjutnya dapat dimanfaatkan untuk perencanaan masa mendatang (*forecasting*).
2. Analisis *time series* dapat membantu dalam peramalan. Analisis Tren dapat digunakan untuk peramalan di masa mendatang.
3. Analisis *time series* dapat membantu memisahkan faktor-faktor yang dapat mempengaruhi suatu data.
4. Analisis *time series* dapat membantu dan mempermudah membandingkan satu rangkaian data dengan rangkaian data yang lain (Boedijoewono, 2012).

3.5 Pola Data Runtun Waktu

Jenis pola data merupakan langkah yang penting untuk menentukan suatu metode peramalan runtun waktu, karena dengan mengetahui jenis pola data maka data dapat untuk menentukan metode peramalan mana yang paling tepat untuk dilakukan pengujian. Terdapat 4 komponen yang mempengaruhi analisis yaitu:

1. Pola Siklis (*Cycle*)

Pola siklis memiliki karakter dari pergerakan seperti gelombang yang lebih panjang dari pada satu tahun dan belum tentu berulang pada interval waktu yang sama. Berbeda dengan karakteristik dari pola musiman yang dimana terjadi pengulangan pola secara konsisten. Berulang-ulang antar waktu kejadian secara periodik adalah bentuk pola siklis. Komponen siklis sangat bermanfaat untuk peramlaan data dalam jangka menengah. Bentuk pola siklis dapat dilihat pada Gambar 3.1.




Gambar 3. 1 Pola Data Siklis

(Sumber : (Makridakis, Wheelwright, & McGee, 1999))

2. Pola musiman (Seasonal)

Pola musiman terjadi jika data setiap periodenya membentuk pola yang sama atau berulang secara periodik yang bergerak secara bebas. Pola ini memiliki karkter yang dimana puncak dan lembah berulang dalam periode yang konsisten. Sebagai contoh pada suatu negara mengalami pergantian cuaca sebanyak 4 kali yaitu musim semi (*spring*), musim panas (*summer*), musim gugur (*fall*) dan musim dingin (*winter*). Pada Gambar 3.2 menjelaskan bahwa nilai pada musim panas merupakan nilai tertinggi dari musim-musim yang lainnya dalam interval waktu tahunan.




Gambar 3. 2 Pola Data Musiman

(Sumber : (Makridakis, Wheelwright, & McGee, 1999))

3. Pola Horizontal

Pola horizontal terjadi apabila di sekitar nilai rata-rata yang konstan terdapat nilai yang berfluktuasi. Fluktuasi disini adalah data naik dan turun tergantung pada kondisi data juga antar data satu dengan data yang lain. Sebagai

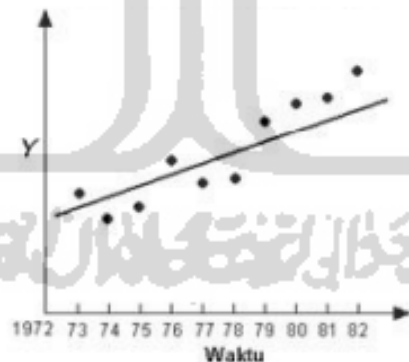
contoh dalam penjualan BBM yang tidak meningkat secara tajam atau menurun secara tajam selama waktu tertentu termasuk ke jenis pola horizontal. Bentuk dari pola horizontal dapat dilihat pada Gambar 33.



Gambar 3. 3 Pola Data Horizontal
(Sumber : (Makridakis, Wheelwright, & McGee, 1999))

4. Pola *Trend*

Pola data yang mengalami naik atau turun menerus sampai waktu (t) tertentu. Sebagai contoh penjualan mobil dan berbagai indikator bisnis dan ekonomi lainnya yang mengikuti suatu pola *trend* selama pembahasannya sepanjang waktu. Bentuk dari pola *trend* dapat Gambar 3.4.




Gambar 3. 4 Pola Data *Trend*
(Sumber : (Makridakis, Wheelwright, & McGee, 1999))

3.6 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan atau yang bisa dikenal dengan istilah *Artificial Neural Network* (ANN) merupakan salah satu bagian dari *machine learning*. Jaringan syaraf tiruan memiliki kemiripan dengan kondisi otak manusia yang terbentuk dari sebagian

besar *neuron* yang memiliki hubungan sangat erat antara *neuron* satu dengan yang lain (Siang, 2009).

Menurut (Fausett, 1994) Jaringan Syaraf Tiruan adalah suatu sistem pemrosesan informasi yang memiliki karakteristik-karakteristik menyerupai jaringan syaraf biologi. Jaringan syaraf manusia terdiri atas sel-sel yang disebut *neuron*. Ada tiga komponen utama *neuron* yang fungsinya dapat dianalogikan dengan yang terjadi pada NN, yaitu *dendrit*, *soma*, dan *akson*. *Dendrit* akan menerima sinyal-sinyal dari *neuron* lain. Sinyal tersebut merupakan impuls listrik yang ditransmisikan melalui *synapatic gap* melalui proses kimia sedangkan, *soma* atau badan sel akan menjumlahkan sinyal-sinyal *input* yang masuk. Jika ada *input* masuk, sel akan aktif dan mentransmisikan sinyal ke sel lain melalui *akson* dan *synapatic gap*.



Gambar 3. 5 Susunan Syaraf Manusia
Sumber : (Hermawan, 2006)

3.6.1 Komponen Jaringan Syaraf Tiruan

Jaringan syaraf tiruan awalnya hanya mempunyai 2 lapisan saja, yaitu *input* dan *output layer*. Seiring berkembangnya waktu, jaringan syaraf tiruan dikembangkan ada yang menambah 1 lapisan lagi yaitu *hidden layer* yang letaknya antara *input* dan *output layer* (Hermawan, 2006). Lapisan dalam jaringan syaraf tiruan dapat dibagi menjadi 3 bagian antara lain:

a. Lapisan *Input* (*Input Layer*)

Berisi *neuron* yang mempunyai nilai masukan masing-masing. *Neuron* tergantung dari banyaknya *input* pada suatu pola. Masukan atau *input* dari lapisan ini menggambarkan suatu masalah.

b. Lapisan Tersembunyi (*Hidden Layer*)

Lapisan yang tersembunyi namun semua proses pada fase pelatihan dan fase pengenalan dijalankan di lapisan ini. Umumnya hanya terdiri dari satu *hidden layer* saja namun juga tergantung dari arsitektur yang akan dirancang. *Hidden Layer* merupakan lapisan yang menghubungkan antara *input layer* dan *output layer*.

c. Lapisan Keluaran (*Output Layer*)


Nilai keluaran dari hasil perhitungan keseluruhan. Hasil keluaran yang dihasilkan merupakan *output JST* dari suatu permasalahan.

3.6.2 Arsitektur Jaringan

Terdapat 3 jenis model arsitektur jaringan syaraf tiruan yaitu:

1. Jaringan Layer Tunggal (*Single Layer Network*)

Pada jaringan ini, sekumpulan *neuron input* dihubungkan langsung dengan *output* nya. Jaringan ini hanya menerima *input* kemudian secara langsung akan mengolahnya menjadi *output* tanpa harus melalui lapisan *hidden*.



Gambar 3. 6 Jaringan Layer Tunggal

Sumber : (Puspitaningrum, 2006)

Keterangan:

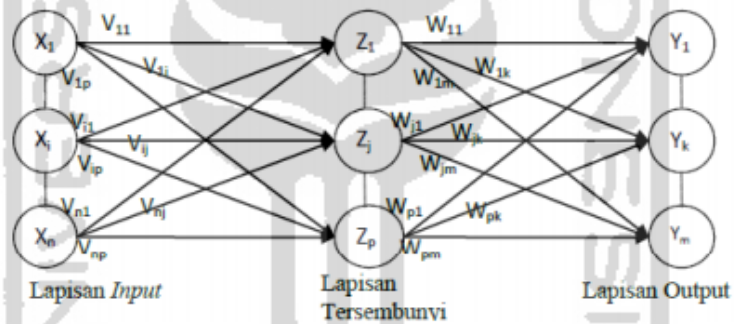
X_1, X_i, X_n = *Input*

Y_1, Y_k, Y_m = *Output*

$W_{11}.. W_{mn}$ = Matriks Bobot

2. Jaringan Layak Jamak (*Multi Layer Network*)

Jaringan dengan banyak lapisan memiliki lapisan yang lebih dari satu yang terletak di antara lapisan *input* dan *output* (memiliki 1 atau lebih lapisan tersembunyi). Dengan menggunakan jaringan *layer* jamak masalah yang kompleks dapat mudah terselesaikan dibandingkan jika memakai *layer* tunggal, meskipun proses pelatihannya kadang lebih lama.



Gambar 3. 7 Jaringan Layer Jamak
Sumber : (Puspitaningrum, 2006)

Keterangan:

$X_1, X_i,$ = *Input*

Z_1, Z_j, Z_p = *Hidden layer*

$Y_1, Y_k,$ = *Output*

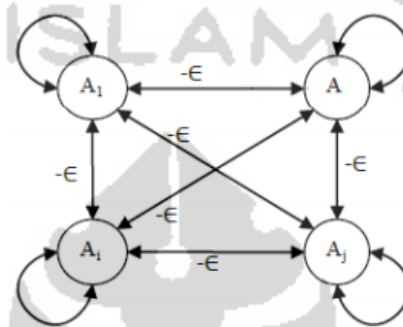
$V_i,$ = Matriks Bobot Pertama

$W_i,$ = Matriks Bobot Kedua

3. Jaringan *Reccurent*

Umumnya, hubungan antara *neuron* pada lapisan kompetitif ini tidak diperlihatkan pada diagram arsitektur. Model jaringan *reccurent* mirip dengan layar tunggal maupun ganda. Hanya aja ada *neuron output* yang memberikan

sinyal pada *unit input* (sering disebut *feedback loop*). Artinya, sinyal mengalir dua arah, yaitu maju dan mundur. Pada lapisan ini jaringan mempunyai minimal satu *feedback loop* yang terdiri dari masing-masing *neuron* untuk memberikan kembali *output* nya sebagai *input* pada *neuron* lain. Nilai bobot untuk tiap *neuron* adalah 1 dan bobot acak negatif dengan $-\epsilon$ untuk neuron lain. Berikut merupakan struktur jaringan- jaringan dengan lapisan kompetitif.



Gambar 3. 8 Jaringan Reccurent
Sumber : (Puspitaningrum, 2006)

Keterangan:

A_1, \dots, A_j = Input

$-\epsilon$ = Bobot Acak Negatif

3.6.3 Fungsi Aktivasi

Dalam jaringan syaraf tiruan terdapat fungsi aktivasi yang dapat digunakan untuk menentukan *output* suatu *neuron* dengan berargumen net *input*. Net *input* terdiri dari kombinasi linier *input* beserta bobotnya (Siang, 2009). Fungsi ini memiliki tujuan untuk memodifikasi *output* kedalam rentang nilai tertentu. Berikut ini adalah fungsi aktivasi yang sering digunakan dalam jaringan syaraf (Kusumadewi S. , 2003) yaitu:

1. Fungsi *sigmoid biner*

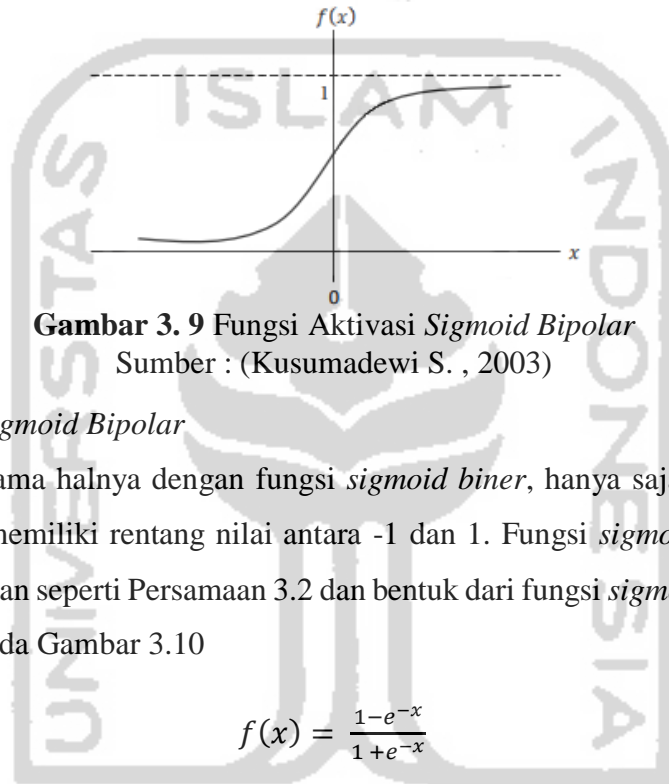
Fungsi *sigmoid biner* memiliki interval *output* 0 sampai 1 dengan membentuk kurva S yang dapat menghasilkan *output* lebih cepat. Fungsi *sigmod biner* dapat dirumuskan seperti Persamaan 3.1 dan bentuk dari fungsi *sigmoid biner* digambarkan pada Gambar 3.9.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.1)$$

Keterangan:

$f(x)$ = Fungsi aktivasi *sigmoid biner*

e^{-x} = Eksponensial pangkat minus data ke- x



Gambar 3. 9 Fungsi Aktivasi Sigmoid Bipolar
Sumber : (Kusumadewi S. , 2003)


2. Fungsi Sigmoid Bipolar

Sama halnya dengan fungsi *sigmoid biner*, hanya saja fungsi *sigmoid bipolar* memiliki rentang nilai antara -1 dan 1. Fungsi *sigmoid bipolar* dapat dirumuskan seperti Persamaan 3.2 dan bentuk dari fungsi *sigmoid bipolar* dapat dilihat pada Gambar 3.10

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (3.2)$$

$f(x)$ = Fungsi aktivasi *sigmoid bipolar*

e^{-x} = Eksponensial pangkat minus data ke- x

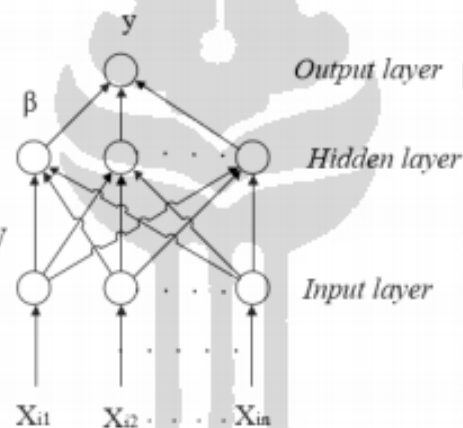


Gambar 3. 10 Fungsi Aktivasi Sigmoid Bipolar
Sumber : (Kusumadewi S. , 2003)

3.7 Extreme Learning Machine (ELM)

Extreme learning machine diperkenalkan oleh (Huang, Zhu, & Siew, 2006). ELM merupakan metode pengembangan dari jaringan syaraf tiruan *feedforward* sederhana dengan menggunakan satu *hidden layer* atau biasa dikenal dengan *Single Hidden Layer Feedforward Neural Network* (SLFNs).

Jaringan *feedforward* menggunakan parameter-parameter yang ditentukan secara manual seperti *input weight* dan bias. *Input weight* dan bias ini dibangkitkan secara acak dalam suatu rentang tertentu. Dengan nilai yang diacak tersebut, bisa menghindari hasil prediksi yang stabil. Secara umum struktur ELM ditunjukkan pada Gambar 3.11



Gambar 3. 11 Struktur Metode ELM
Sumber : (Giusti, Widodo, & Adinugroho, 2018)

Keterangan:

y = Nilai *output layer*

β = *Output weight*

X = *Input data yang digunakan*

W = *Bobot input*

n = Jumlah *input neuron*

Langkah-langkah dalam meakukan prediksi menggunakan ELM adalah sebagai berikut:

3.7.1 Normalisasi Data

Normalisasi data merupakan metode *preprocessing* yang bertujuan untuk standarisasi seluruh data yang digunakan agar berada pada jarak tertentu. Salah satu metode yang digunakan untuk normalisasi data yaitu dengan menggunakan metode *Min-Max Normalization*. *Min-Max Normalization* merupakan metode normalisasi dengan melakukan transformasi linier terhadap data asli sehingga menghasilkan keseimbangan nilai perbandingan antar data saat sebelum dan sesudah proses. Berikut adalah metode *Min-Max Normalization* yang digunakan dalam proses normalisasi data yang ditunjukkan pada Persamaan 3.3 (Nasution, Khotimah, & Chamidah, 2019):

$$X_i' = X_{minb} + \frac{(X_t - X_{min})(X_{maxb} - X_{minb})}{(X_{max} - X_{min})} \quad (3.3)$$

Keterangan:

- X_i' = Nilai normalisasi
- X_t = Nilai data aktual atau observasi
- X_{min} = Nilai minimum pada data aktual
- X_{max} = Nilai maksimum pada data aktual
- X_{minb} = Nilai maksimum baru
- X_{maxb} = Nilai maksimum baru

3.7.2 Proses Training

Proses *training* harus dilalui sebelum melakukan proses prediksi. Tujuannya adalah untuk mendapatkan nilai *output weight*. Langkah-langkah proses *training* yaitu bagai berikut (Huang, Zhu, & Siew, 2006) :

1. Langkah pertama adalah meginisialisasi *weight* dan bias. Nilai ini diinisialisasi secara acak.
2. Tiap unit masukan $X_i (i = 1, 2, \dots, n)$ menerima sinyal dan meneruskan sinyal tersebut ke semua unit pada lapisan *hidden*.

3. Keluaran di *hidden layer* dihitung menggunakan fungsi aktivasi. Langkah selanjutnya adalah menghitung keluaran *hidden layer* (Z_{net_j}), dengan menggunakan persamaan sebagai berikut:

$$Z_{net_j} = \left(\sum_{i=1}^n X_i V_{ij} \right) + V_{oj} \quad (3.4)$$

Keterangan:

Z_{net_j} = Faktor keluaran pada unit tersembunyi

i = [1,2,...,N], dimana N adalah keseluruhan banyak jumlah data.

j = [1,2,...,Ñ], dimana Ñ adalah keseluruhan jumlah *hidden neuron*.

n = Jumlah *input neuron*

V = Bobot *input weight*

X = *Input data yang digunakan*

V_o = Nilai bias.

Setelah nilai Z_{net_j} didapatkan, selanjutnya dihitung menggunakan aktivasi *sigmoid biner*, bisa dilihat pada persamaan berikut

$$Z_j = \frac{1}{1 + \exp(-z_{net_j})} \quad (3.5)$$

Keterangan:

Z_j = Nilai dari fungsi aktivasi keluaran pada unit tersembunyi

Z_{net_j} = Faktor keluaran pada unit tersembunyi

4. Menghitung *output weight*. Untuk mendapatkan *output weight*, langkah pertama yang harus dilakukan adalah mentraspose matriks hasil keluaran *hidden layer* dengan fungsi aktivasi. Setelah ditranspose, matriks transpose tersebut dikalikan dengan matriks hasil keluaran *hidden layer* dengan fungsi aktivasi bisa disebut matriks Z_j . Langkah selanjutnya adalah menghitung nilai *invers* dari matriks Z_j tersebut. Setelah itu menghitung matriks *Moore-Penose Generalized Invers* dari hasil keluaran *hidden layer*. Berikut persamaan untuk mencari matriks *Moore-Penose Generalized Invers*:

$$Z_j^+ = ((Z_j)^T Z_j)^{-1} Z_j^T \quad (3.6)$$

Keterangan:

Z_j^+ = Matriks *Moore-Penrose Generalized Invers* dari matriks Z_j

Z_j^T = Matriks Z_j transpose

Z_j = Nilai dari fungsi aktivasi keluaran pada unit tersembunyi

Melakukan perhitungan *output weight* (bobot antara layer dan juga *output layer*) dengan perkalian antara invers matriks dan matriks target. Berikut adalah persamaan untuk menghitung nilai *output weight*:

$$\beta = Z_j^+ T \quad (3.7)$$

Keterangan:

β = Matriks *output weight*

Z_j^+ = Matriks *Moore-Penrose Generalized Invers* dari matriks Z_j

T = Matriks Target

3.7.3 Proses *Testing*

Pada proses ini bertujuan untuk mengevaluasi metode ELM dari hasil proses *training* sebelumnya. Proses *testing* dilakukan menggunakan *input weight*, bias dan *output weight* yang didapatkan dari proses *training*. Berikut langkah-langkah proses *testing* adalah sebagai berikut:

1. Langkah pertama adalah menginisialisasi *input weight* dan bias yang telah didapatkan dari proses *training*.
2. Keluaran di *hidden layer* dihitung menggunakan fungsi aktivasi. Pilih salah satu fungsi aktivasi yang digunakan yaitu fungsi aktivasi *sigmoid*.
3. Nilai *output weight* yang telah didapatkan pada proses *training* digunakan untuk menghitung keluaran *ouput layer* yang merupakan hasil prediksi. Berikut adalah persamaan untuk menghitung nilai *ouput layer*:

$$y = Z_j \beta \quad (3.8)$$

Keterangan:

y = Nilai *output* (prediksi)

β = Matriks *output weight* (didapatkan dari proses *training*)

Z_j = Nilai dari fungsi aktivasi keluaran pada unit tersembunyi

4. Langkah terakhir adalah menghitung nilai *error* semua *output layer*. Nilai *error* ini menunjukkan nilai kesalahan dari hasil prediksi yang didapatkan.

3.7.4 Proses Denormalisasi Data

Proses ini berfungsi untuk membangkitkan nilai yang telah dinormalisasi menjadi nilai asli. Berikut adalah persamaan untuk proses denormalisasi data:

$$X_t = X_{minb} + (X_t' (X_{max} - X_{min})) + X_{min} (X_{maxb} - X_{minb}) \quad (3.9)$$

Keterangan:

X_t' = Nilai hasil prediksi sebelum didenormalisasi

X_t = Nilai data aktual atau observasi

X_{min} = Nilai minimum pada data aktual

X_{max} = Nilai maksimum pada data aktual

X_{minb} = Nilai maksimum baru

X_{maxb} = Nilai maksimum baru

3.8 Algoritma Jaringan Syaraf Tiruan *Backpropagation*

Jaringan Syaraf Tiruan *Backpropagation* pertama kali diperkenalkan oleh Rumelhart, Hinton, dan William pada tahun 1986, kemudian Rumelhart dan McClelland mengembangkannya metode ini pada tahun 1988. Jaringan syaraf tiruan *backpropagation* akan mengubah bobot biasanya untuk mengurangi perbedaan antara *output* jaringan dan target *output*. Umumnya jaringan syaraf tiruan dengan pembelajaran terawasi (*supervised learning*) dengan banyak lapisan (*multi layer network*) yang minimal terdiri dari *input layer*, *hidden layer*, dan *output layer*.

Algoritma *Backpropagation* disebut propagasi balik karena jaringan diberikan pola masukan sebagai pola pelatihan maka pola tersebut menuju ke unit-unit pada lapisan tersembunyi untuk diteruskan ke unit-unit lapisan keluaran, selanjutnya, unit-unit lapisan keluaran memberikan tanggapan yang disebut keluaran jaringan. Saat keluaran jaringan tidak sama dengan keluaran yang diharapkan maka keluaran akan

menyebar mundur (*backward*) pada lapisan tersembunyi diteruskan ke unit lapisan masukan. Oleh karena itu mekanisme pelatihan tersebut dinamakan *backpropagation* (Kusumadewi F. , 2014).

Backpropagation merupakan algoritme pembelajaran yang terawasi dan biasanya digunakan oleh *perceptron* dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan *neuron-neuron* yang ada pada lapisan tersembunyi. Algoritme *backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan *error* ini, tahap perambatan maju (*forward propagation*) harus dikerjakan terlebih dahulu (Irwansyah & Faisal, 2015).

Backpropagation merupakan salah satu metode pelatihan jaringan syaraf tiruan terawasi (*supervised learning*) yang terdiri atas 3 langkah utama yakni:

1. Data dimasukkan dalam *input* jaringan (*Feedforward*).
2. Perhitungan dan propagasi balik dari *error* yang ditemukan (*backpropagation*)
3. Pembaharuan bobot dan bias.

Langkah-langkah dalam algoritma *backpropagation* oleh (Fausett, 1994) adalah sebagai berikut :

Langkah 0: Inisialisasi bobot (set bobot pada nilai *random* yang kecil).

Langkah 1: Jika kondisi penghentian belum terpenuhi, kerjakan langkah 2-9.

Langkah 2: Untuk setiap pasangan *training*, lakukan 3-8.

FeedForward

Langkah 3: Setiap unit *input* (X_i , $i = 1, 2, 3, \dots, n$) menerima sinyal *input* X_i dan meneruskan sinyal ini kepada semua unit pada lapisan di atasnya (*hidden unit*)

Langkah 4: Masing-masing unit *hidden layer* dikalikan dengan faktor penimbang dan dijumlahkan serta ditambahkan dengan biasnya.

$$Z_{net_j} = V_{0j} + \sum_{i=1}^n X_i V_{ij} \quad (3.10)$$

Keterangan:

Z_{net_j} = Faktor keluaran pada unit tersembunyi

V_{0j} = Bobot bias pada unit tersembunyi

X_i = Unit *input*

V_{ij} = Bobot unit *input* terhadap unit tersembunyi

gunakan fungsi aktivasi untuk menghiung sinyal *output*, jika menggunakan fungsi *sigmoid* maka fungsi adalah berikut ini:

$$Z_j = \frac{1}{1 + \exp(-Z_{net_j})} \quad (3.11)$$

Keterangan:

Z_j = Nilai dari fungsi aktivasi keluaran pada unit tersembunyi

Z_{net_j} = Faktor keluaran pada unit tersembunyi

kemudian mengirim sinyal tersebut ke semua unit pada *output layer*

Langkah 5: Tiap-tiap unit di *output layer* ($Y_k, k = 1, 2, 3, \dots, m$) menjumlahkan sinyal-sinyal masuk yang berbobot menggunakan berikut:

$$Y_{net_k} = W_{ok} + \sum_{j=1}^p Z_j W_{jk} \quad (3.12)$$

Keterangan:

Y_{net_k} = Faktor keluaran pada unit *output*

W_{ok} = Bobot bias pada unit *output*

Z_j = Nilai dari fungsi aktivasi pada unit tersembunyi

W_{jk} = Bobot unit tersembunyi terhadap unit *output*

gunakan fungsi aktivasi untuk menghitung sinyal *output*, seperti persamaan berikut:

$$Y_k = \frac{1}{1 + \exp(-Y_{net_k})} \quad (3.13)$$

Keterangan:

Y_k = Nilai dari fungsi aktivasi keluaran pada unit *output*

Y_{net_k} = Faktor keluaran pada unit *output*

Backpropagation

Langkah 6: Tiap unit di *output* layer ($Y_k, k = 1, 2, 3, \dots, m$) menerima pola target berkaitan dengan pola pelatihan masuknya. Hitung galat informasi menggunakan persamaan berikut:

$$\delta_k = (t_k - Y_k)f'(Y_{net_k}) = (t_k - Y_k)Y_k(1 - Y_k) \quad (3.14)$$

Keterangan:

δ_k = Faktor kesalahan pada lapisan *output*

t_k = target yang dicapai

Y_k = Nilai dari fungsi aktivasi keluaran pada unit *output*

kemudian hitung koreksi bobot (digunakan untuk memperbaiki W_{jk}) persamaan yang digunakan sebagai berikut:

$$\Delta W_{jk} = \alpha \delta_k Z_j \quad (3.15)$$

Keterangan:

ΔW_{jk} = Suku perubahan bobot

α = konstanta laju pelatihan (*learning rate*)

δ_k = Faktor kesalahan pada lapisan tersembunyi

Z_j = Nilai dari fungsi aktivasi pada unit tersembunyi

hitung juga nilai korelasi bias (digunakan untuk memperbaiki W_{0k}) dengan menggunakan persamaan berikut ini:

$$\Delta W_{0k} = \alpha \delta_k \quad (3.16)$$

Keterangan:

ΔW_{0k} = Suku perubahan bobot bias

α = konstanta laju pelatihan (*learning rate*)

δ_k = Faktor kesalahan pada lapisan tersembunyi.

Langkah 7: Tiap unit di *hidden layer* ($Z_j =$ menjumlahkan delta masukannya (dari unit-unit pada lapisan di atasnya)) dengan menggunakan persamaan sebagai berikut :

$$\delta_{net_j} = \sum_{k=1}^m \delta_k W_{jk} \quad (3.17)$$

Keterangan:

δnet_j = Jumlah kesalahan dari unit tersembunyi

δ_k = Faktor kesalahan pada lapisan *output*

W_{jk} = Bobot unit tersembunyi terhadap unit *output*

kalikan nilai ini dengan turunan fungsi aktivasinya untuk menghitung informasi *error* dengan persamaan berikut:

$$\delta_j = \delta net_j f'(Znet_j) = \delta net_j Z_j (1 - Z_j) \quad (3.18)$$

Keterangan:

δ_j = Faktor kesalahan pada lapisan tersembunyi

δnet_j = Jumlah kesalahan dari unit tersembunyi

Z_j = Nilai dari fungsi aktivasi pada unit tersembunyi

kemudian hitung koreksi bobot (digunakan untuk memperbaiki V_{ij}) menggunakan persamaan berikut ini :

$$\Delta V_{ij} = \alpha \delta_j X_i \quad (3.19)$$

Keterangan:

ΔV_{ij} = Suku perubahan bobot ke unit tersembunyi

α = konstanta laju pelatihan (*learning rate*)

δ_j = Faktor kesalahan pada lapisan tersembunyi

X_i = Unit *input*

hitung juga koreksi bias (digunakan untuk memperbaiki V_{0j}) menggunakan berikut ini:

$$\Delta V_{0j} = \alpha \delta_j \quad (3.20)$$

Keterangan:

ΔV_{0j} = Suku perubahan bobot ke unit tersembunyi bobot bias

α = konstanta laju pelatihan (*learning rate*)

δ_j = Faktor kesalahan pada lapisan tersembunyi

Perubahan Bobot dan Bias

Langkah 8: Tiap unit di *output* layer ($Y_k, k = 1, 2, 3, \dots, m$) melakukan bias dan bobotnya ($j = 1, 2, 3, \dots, p$) dengan menggunakan persamaan sebagai berikut:

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (3.21)$$

Keterangan:

W_{jk} = Bobot unit tersembunyi terhadap unit *output*

ΔW_{jk} = Suku perubahan bobot

setiap unit di *hidden* layer ($Z_j, j = 1, 2, 3, \dots, p$) melakukan perubahan bobot dan bias yang berasal dari tiap unit di *input* layer ($X_i, i = 1, 2, 3, \dots, n$) menggunakan persamaan sebagai berikut:

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (3.22)$$

Keterangan:

V_{ij} = Bobot unit *input* terhadap unit tersembunyi

ΔV_{ij} = Suku perubahan bobot ke unit tersembunyi

Langkah 9: Proses pelatihan atau *training* akan berhenti ketika kondisi telah terpenuhi, namun jika belum terpenuhi maka lakukan 2-9.

3.9 Ukuran Kesalahan Peramalan

Untuk suatu peramalan adanya evaluasi terhadap suatu hasil peramalan, dengan menggunakan ukuran kesalahan peramalan. Hasil peramalan yang terbaik memiliki nilai kesalahan peramalan yang terkecil. Ukuran kesalahan yang digunakan dalam penelitian ini adalah termasuk ukuran standar statistik adalah nilai rata-rata kesalahan kuadrat (*Mean square error*) dan nilai rata-rata kesalahan presentase absolut (*Mean Absolute Percentage Error*).

3.9.1 MSE (*Mean square error*)

Mean square error adalah metode untuk mengevaluasi metode peramalan. Masing-masing kesalahan atau bias dikuadratkan kemudian dijumlahkan dan dibagi

dengan jumlah observasi. Pendekatan ini mengatur kesalahan peramalan yang besar karena kesalahan-kesalahan itu dikuadratkan. Berikut adalah persamaannya:

$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n (X_t - y_t)^2 \quad (3.23)$$

Keterangan:

n = Jumlah data

y_t = Nilai *output* (prediksi) pada periode ke-t

X_t = Nilai data aktual atau observasi pada periode ke-t

3.9.2 MAPE (*Mean Absolute Percentage Error*)

Mean Absolute Percentage Error merupakan pengukuran besarnya kesalahan dengan menghitung ukuran presentase penyimpangan antara data aktual dengan data peramalan yang diperoleh. Dengan rumus sebagai berikut:

$$\text{MAPE} = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{x_t - y_t}{x_t} \right| \quad (3.24)$$

Keterangan:

n = Jumlah data

y_t = Nilai *output* (prediksi) pada periode ke-t

X_t = Nilai data aktual atau observasi pada periode ke-t

Menurut (Moreno, Pol, Abad, & Blasco, 2013) inteprestasi dari nilai MAPE adalah sebagai berikut:

Tabel 3. 1 Interprestasi Nilai MAPE

MAPE	Interprestasi
<10	Kemampuan peramalan sangat baik
10-20	Kemampuan peramalan baik
20-50	Kemampuan peramalan layak/memadai
>50	Kemampuan peramalan buruk

BAB IV

METODE PENELITIAN

4.1 Populasi Penelitian

Populasi dalam penelitian ini adalah harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk. Sampel yang digunakan dalam penelitian adalah harga penutupan saham PT. Bank Mandiri (Persero) Tbk pada periode 14 Januari 2019 sampai dengan 13 Januari 2020. Tujuan dalam penelitian ini adalah untuk mengetahui hasil prediksi harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk.

4.2 Jenis dan Sumber Data

Data dalam penelitian yang digunakan adalah data sekunder, dimana peneliti tidak turun langsung kelapangan untuk memperoleh data, melainkan diperoleh dari <https://finance.yahoo.com/> yang sudah menyediakan data harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk.

4.3 Variabel Penelitian

Variabel yang digunakan dalam penelitian ini adalah harga penutupan (*closing price*) saham PT. Bank Mandiri (Persero) Tbk yang dimulai dari tanggal 14 Januari 2019 sampai dengan 13 Januari 2020. Dalam penelitian ini menggunakan harga penutupan dikarenakan harga penutupan saham digunakan sebagai acuan dalam harga pembukaan.

4.4 Metode Analisis Data

Data yang digunakan pada penelitian ini adalah analisis deskriptif dan menggunakan metode peramalan yaitu metode *Extreme Learning Machine* dan metode *Backpropagation*. Kedua metode peramalan ini untuk membandingkan hasil peramalan dari ELM dan *Backpropagation*. Kemudian akan ditentukan metode yang terbaik untuk dilakukan peramalan dengan menggunakan data harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk dengan melihat ukuran kesalahan atau nilai

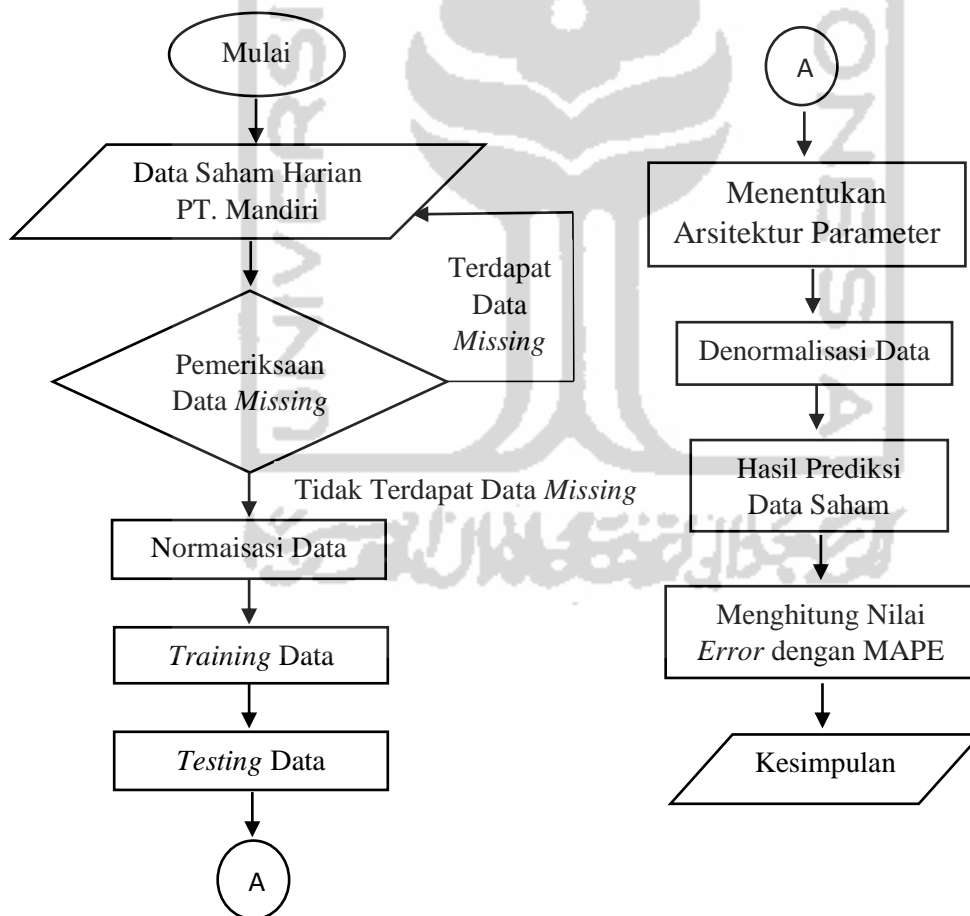
error peramalan yaitu *Mean Absolute Percentage Error* (MAPE). Alat bantu yang digunakan untuk penelitian adalah perangkat lunak yaitu *Microsoft Exel 2016* dan *Rstudio R-3.6.1*.

4.5 Tahap Penelitian

Sebelum dilakukannya implementasi terlebih dahulu diperlukan sebuah alur pada proses perancangan dalam suatu sistem prediksi. Dengan metode ELM dan *Backpropagation*.

4.5.1 Tahap penelitian *Extreme Learning Machine* (ELM)

Berikut adalah merupakan gambaran dari sebuah diagram alir proses *Extreme Learning Machine* yang dijelaskan pada Gambar 4.1:

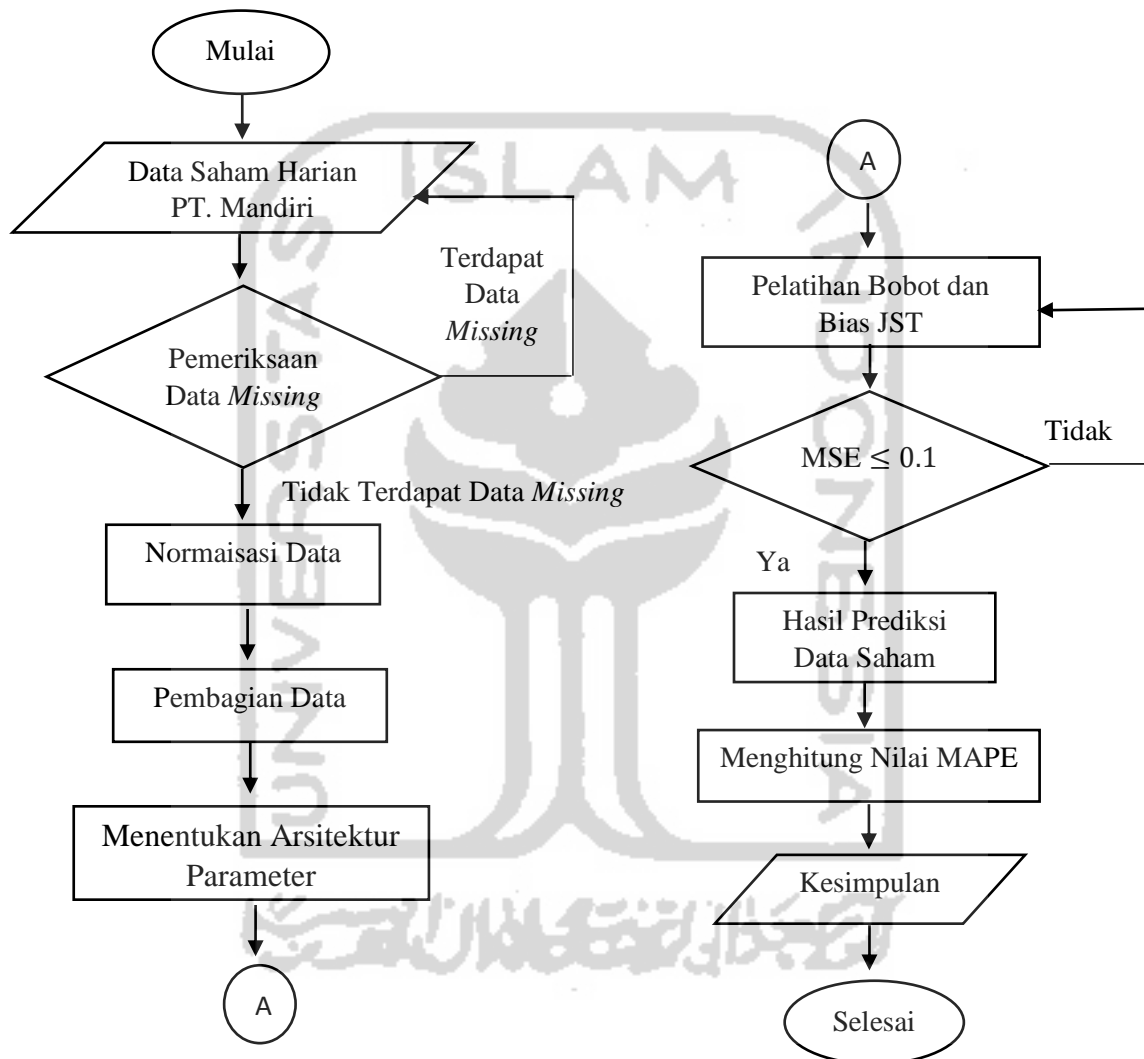


Gambar 4. 1 Diagram ELM

Dari Gambar 4.1 merupakan suatu *flowchart* dari sebuah sistem prediksi harga saham dari PT. Bank Mandiri (Persero) Tbk dengan menggunakan metode *Extreme Learning Machine*. Langkah awal yang dilakukan adalah meng-*input* data harga penutupan saham PT. Bank Mandiri (Persero) Tbk. Dalam suatu analisis tentunya perlu pengecekan ada tidaknya data *missing*, maka dari itu proses data *missing* sangat diperlukan, pemeriksaan data *missing* dilakukan untuk memastikan ada tidaknya informasi atau data yang hilang dan jika terdapat data *missing*, maka akan diatasi dengan inputan data *missing* jika tidak terdapat maka lanjut ke proses selanjutnya. Langkah selanjutnya melakukan proses normalisasi data, normalisasi dilakukan untuk memastikan bahwa *input* ELM yang digunakan berada pada suatu interval yang sama. Data masukkan yang di normalisasi menggunakan *Min-Max normalization*. Proses selanjutnya yaitu melakukan *training* dan *testing* pada data, proses *training* yang dilakukan sebelum melakukan prediksi dengan tujuan untuk mendapatkan nilai *output weight* optimal atau memiliki tingkat kesalahan rendah, sedangkan proses *testing* bertujuan untuk mengevaluasi potensi metode pada ELM dalam hal prediksi. Selanjutnya menentukan arsitektur nilai parameter, kemudian lakukan proses denormalisasi pada data untuk membangkitkan nilai yang telah dinormalisasikan menjadi nilai asli. Kemudian didapatkan nilai hasil prediksi dari harga penutupan saham PT. Bank Mandiri (Persero) Tbk dan akan dihitung nilai kesalahan peramalan atau *error* dengan menggunakan perhitungan *Mean Absolute Percentage Error* (MAPE). Setelah itu, dilakukan penyajian data dan mendapatkan kesimpulan.

4.5.2 Tahap penelitian *Backpropagation*

Berikut adalah merupakan gambaran dari sebuah diagram alir proses *Backpropagation* yang dijelaskan pada Gambar 4.2:



Gambar 4. 2 Diagram Alir *Backpropagation*

Sumber: Peneliti

Dari Gambar 4.2 merupakan suatu *flowchart* dari jaringan syaraf tiruan *Backpropagation* dari sebuah sistem prediksi harga saham PT. Bank Mandiri (Persero) Tbk. Langkah awal yang dilakukan adalah meng-*input* data harga penutupan saham PT. Bank Mandiri (Persero) Tbk, kemudian terdapat pemeriksaan data *missing*

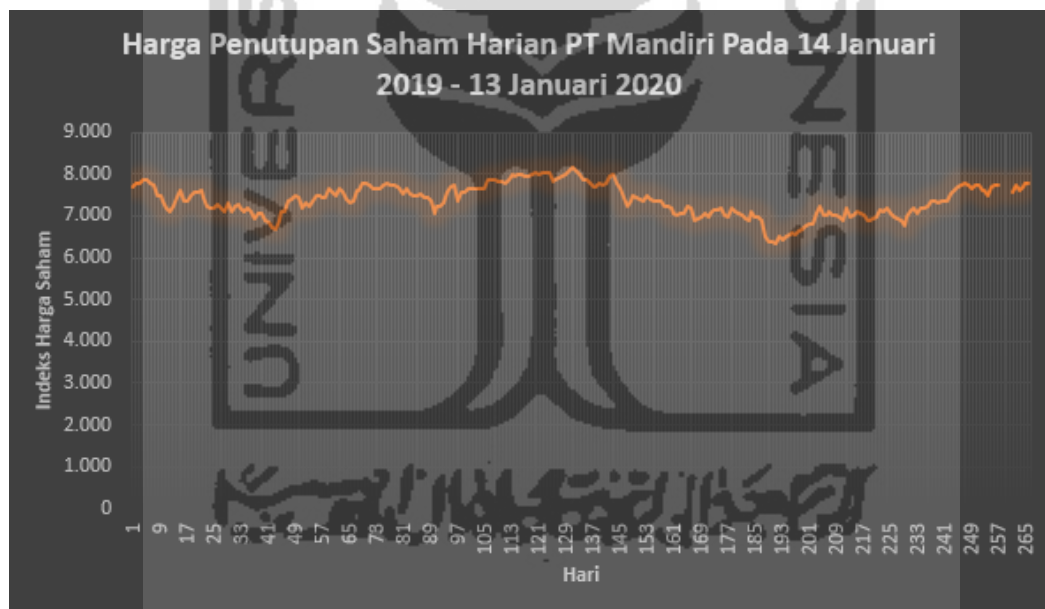
dilakukan untuk memastikan ada tidaknya informasi atau data yang hilang jika terdapat data *missing* maka akan diatasi dengan inputan data *missing* jika tidak terdapat maka lanjut ke proses selanjutnya yaitu normalisasi data, normalisasi data dilakukan untuk mengubah skala pengukuran dari data asli menjadi bentuk data skala sehingga memiliki nilai skala yang sama. Tahap selanjutnya yaitu tahap pembagian data *training* dan data *testing*. Selanjutnya menentukan arsitektur nilai parameter dimana susunan jaringan yang terdiri dari jumlah unit *input*, jumlah unit *hidden layer* dan jumlah unit *output*. Kemudian melakukan pelatihan bobot dan bias pada Jaringan Saraf Tiruan, nilai bobot dan bias diberikan dengan cara melakukan pembangkitan nilai acak. Kemudian dilihat hasil nilai galat atau *error* dimana nilai kondisi error yang digunakan adalah nilai MSE, jika nilai MSE sudah optimal atau ≤ 0.1 maka akan dilanjutkan ke tahap berikutnya jika belum maka akan kembali ke langkah pelatihan bobot dan bias. Setelah itu mendapatkan hasil prediksi dari harga penutupan saham PT. Bank Mandiri (Persero) Tbk, langkah selanjutnya menghitung nilai MAPE untuk mendapatkan hasil validasi dari metode untuk nilai peramalan. Dan langkah terakhir adalah kesimpulan.

BAB V

PEMBAHASAN

5.1 Analisis Deskriptif

Penelitian ini menggunakan perbandingan metode yaitu metode *Extreme Learning Machine* dan *Backpropagation*, namun sebelum dilakukannya analisis peneliti terlebih dahulu melakukan analisis deskriptif dari variabel yang digunakan. Analisis Deskriptif dalam penelitian ini digunakan untuk menjelaskan secara singkat mengenai gambaran umum dari harga penutupan saham PT. Bank Mandiri (Persero) Tbk pada periode 14 Januari 2019 sampai dengan 13 Januari 2020.



Gambar 5. 1 Harga Penutupan Saham PT. Bank Mandiri (Persero) Tbk

Grafik harga penutupan saham PT. Bank Mandiri (Persero) Tbk yang di terangkan dari Gambar 5.1 harga penutupan saham terendah yaitu sebesar 6,350 yang terjadi pada tanggal 7 Oktober 2019 dan harga penutupan saham tertinggi yaitu sebesar 8,150 yang terjadi pada tanggal 15 Juli 2019. Kemudian rata-rata dari harga penutupan saham yaitu sebesar 7,370. Harga penutupan saham PT. Bank Mandiri (Persero) Tbk

cenderung memiliki pola horizontal, data tidak memiliki kenaikan atau penurunan yang sangat drastis.

5.2 Metode *Extreme Learning Machine* (ELM)

5.2.1 Pemeriksaan Data *Missing*

Missing data adalah informasi yang hilang atau tidak tersedia untuk suatu objek. Pemeriksaan data *missing* ini untuk memastikan ada tidaknya informasi atau data yang hilang. Jika ada data *missing* hal ini menyebabkan menurunnya keakuratan dan kualitas pada saat data diolah, maka dari itu perlu adanya pemeriksaan data *missing*. Jika suatu data terdapat informasi yang tidak tersedia pada salah satu variable objek atau kasus tertentu maka akan dilakukannya perbaikan data. Pada penelitian dengan menggunakan metode *Extreme Learning Machine* ini tidak ada terjadinya data *missing* atau keseluruhan data yang digunakan lengkap.

5.2.2 Normalisasi Data

Data saham PT. Bank Mandiri (Persero) Tbk terlebih dahulu di normaliasikan, normalisasi dilakukan menggunakan data *Min-Max Normalization* dengan menggunakan rumus Persamaan (3.3).

5.2.3 Pembagian Data *Training* dan *Data Testing*

Proses *Training* digunakan untuk mengevaluasi ELM sebagai alat peramalan. Data hasil untuk proses *training* pada data saham harian PT. Bank Mandiri (Persero) Tbk adalah sebagai berikut:

Tabel 5. 1 Pola *Input* Data *Training*

Pola Ke-	Data <i>Input</i>					
	Y	X ₁	X ₂	X ₃	X ₄	X ₅
1	0.48889	0.55556	0.55556	0.48889	0.48889	0.40000
2	0.44444	0.48889	0.55556	0.55556	0.48889	0.48889
3	0.20000	0.44444	0.48889	0.55556	0.55556	0.48889
4	0.20000	0.20000	0.44444	0.48889	0.55556	0.55556
5	0.11111	0.20000	0.20000	0.44444	0.48889	0.55556
6	-0.06667	0.11111	0.20000	0.20000	0.44444	0.48889

Pola Ke-	Y	X ₁	X ₂	X ₃	X ₄	X ₅
...
...
245	0.44444	0.37778	0.44444	0.48889	0.42222	0.40000
246	0.42222	0.44444	0.37778	0.44444	0.48889	0.42222
247	0.31111	0.42222	0.40000	0.37778	0.44444	0.48889

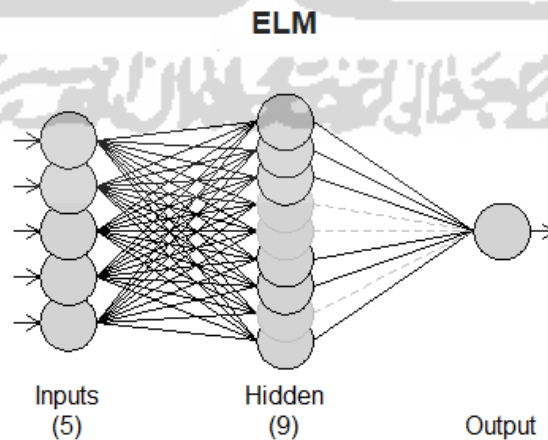
Nilai data dari data *input* yaitu X₁, X₂, X₃, X₄, dan X₅ adalah nilai *input* dari data yang digunakan yang berjumlah sebanyak 5 *input* dikarenakan penutupan harga saham yang terjadi dalam seminggu sebanyak 5 hari sedangkan, nilai dari Y adalah nilai target yang ada pada proses *training* metode *Extreme Learning Machine*. Hasil presentase pembagian data yang digunakan adalah sebagai berikut:

Tabel 5. 2 Pembagian Data *Training* dan *Testing*

Pembagian	Presentase	Total Data
Data <i>Training</i>	98%	252
Data <i>Testing</i>	2%	5
Total	100%	257

5.2.4 Arsitektur Jaringan *Extreme Learning Machine*

Arsitektur jaringan adalah sebuah susunan jaringan yang terdiri dari jumlah unit *input*, jumlah unit *hidden layer* dan jumlah unit *output*.



Gambar 5. 2 Arsitektur Jaringan Saham PT. Bank Mandiri (Persero) Tbk

Dari Gambar 5.2 merupakan gambaran asitektur data yang digunakan dalam proses prediksi dari metode *Extreme Learning Machine* data harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk. *Neuron input* pada asitektur data yaitu sebanyak 5 *neuron* yang diasumsikan merupakan perwakilan dari 5 hari dikarenakan penutupan harga saham yang terjadi dalam seminggu sebanyak 5 hari. *Neuron output* pada asitektur data yaitu sebanyak 1 *Neuron* yang merupakan hasil dari peramalan. Pengujian jumlah *neuron* pada *hidden layer* menunjukkan bahwa dengan jumlah *neuron* yang banyak maka akan mendapatkan nilai *error* yang lebih kecil. Pada penelitian ini peneliti akan membandingkan jumlah menggunakan *hidden layer* menggunakan *hidden neuron* 2 hingga 10 *neuron*, bertujuan untuk mengetahui jumlah *neuron* yang terbaik berdasarkan nilai MSE (*Mean square error*).

Tabel 5.3 Uji Coba Jumlah Neuron Pada *Hidden Layer*

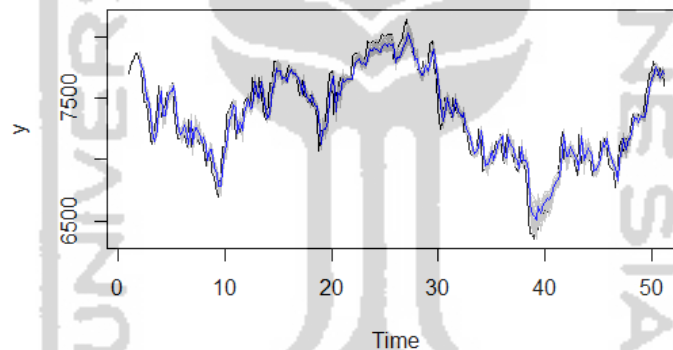
Jumlah <i>Hidden Neuron</i>	Nilai MSE
2	0.0246
3	0.0197
4	0.0161
5	0.0149
6	0.0143
7	0.0138
8	0.0138
9	0.0133
10	0.0137

Dapat dilihat dari hasil Tabel 5.3 percobaan uji coba jumlah *neuron* pada *hidden layer*, pengujian bahwa menggunakan jumlah *neuron* sebanyak 9 nilai dari MSE yang dihasilkan sebesar 0.0133 sedangkan, menggunakan jumlah *neuron* sebanyak 2, nilai dari MSE yang dihasilkan sebesar 0.0246. Menurut (Saputri & Ekojono, 2018) nilai *error* yang tinggi tersebut dikarenakan *underfitting*. *Underfitting* terjadi ketika proses *training* tidak dapat menangkap pola pembelajaran dengan baik dikarenakan pemrosesan *input* atau disebut dengan *hidden neuron* berjumlah sedikit, sehingga pola

yang ditangkap pada proses *training* terbatas dan menyebabkan *error* yang tinggi ketika proses *testing* dijalankan. Kesimpulannya adalah pada penelitian ini menggunakan jumlah *neuron hidden layer* sebanyak 9 *neuron* karena tingkat *error* nya yang lebih kecil.

5.2.5 Hasil Prediksi

Hasil dari prediksi data penutupan saham harian dari PT. Bank Mandiri (Persero) Tbk dalam peramalan menggunakan metode *Extreme Learning Machine*. Dengan menggunakan program *RStudio* dijelaskan dengan menggunakan plot antara perbandingan data asli dan prediksi untuk melihat kemiripan dan memperhitungkan nilai kesalahan pada peramalan. Plot perbandingan data asli dan data prediksi adalah sebagai berikut:



Gambar 5. 3 Plot Data Asli dan Data Prediksi Metode ELM

Dapat dilihat dari Gambar 5.3 yang merupakan hasil plot dari perbandingan data asli dan data prediksi pada metode *Extreme Learning Machine*. Terdapat sumbu x yang merupakan waktu dari data saham sedangkan, sumbu y merupakan jumlah dari data saham harian PT. Bank Mandiri (Persero) Tbk dalam satuan millimeter (mm). Garis berwarna hitam yang merupakan dari data asli sedangkan, garis berwarna biru yang merupakan dari data hasil prediksi. Dari Gambar 5.3 yang merupakan plot perbandingan data asli dan data prediksi. Dapat dilihat dari hasil plot perbandingan antara data asli dan prediksi dimana garis dari data prediksi yang tidak jauh beda dengan data asli, atau data prediksi mengikuti pola dari data asli. Untuk hasil lebih

jelasanya berikut hasil perbandingan data asli dan data prediksi pada proses data *training*:

Tabel 5. 4 Data Aktual Dan Prediksi Metode *Extreme Learning Machine*

Tanggal	Data Aktual	Data Prediksi
21/01/2019	7,800	7,818
22/01/2019	7,750	7,772
23/01/2019	7,475	7,725
24/01/2019	7,475	7,498
25/01/2019	7,375	7,502
...
07/01/2020	7,600	7,756
08/01/2020	7,500	7,714
09/01/2020	7,700	7,665
10/01/2020	7,725	7,722
13/01/2020	7,725	7,700

Dari hasil prediksi harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk dengan menggunakan metode *Extreme Learning Machine* menggunakan pelatihan data memberikan nilai *Mean square error* (MSE) sebesar 0.0133. Kemudian didapatkan juga nilai *Mean Absolute Percentage Error* (MAPE) sebesar 1.243%

5.3 Metode *Backpropagation*

Penerapan model *Feedforward Neural Network* algoritma *Backpropagation*, untuk melakukan peramalan terhadap harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk. Ada beberapa tahapan persiapan data yang akan dilakukan pengujian dengan menggunakan metode *Backpropagation* yaitu adalah pemeriksaan data *missing*, normalisasi data yang digunakan, serta membagi data menjadi dua bagian (*data partition*) yaitu data *training* dan data *testing*.

5.3.1 Pemeriksaan Data *Missing*

Pemeriksaan data *missing* perlu dilakukan sebelum penelitian dimana sudah dijelaskan pemeriksaan data *missing*, di metode *Backpropagation* ini juga melakukan

pemeriksaan data *missing*. Dimana hasil dari pemerksaan data *missing* dari metode *Backpropagation* adalah sebagai berikut:

Tabel 5. 5 Hasil Pemeriksaan Data *Missing*

Variabel	Valid	Missing	Persentase Valid
PT. Mandiri	257	0	100%
X2	257	0	100%
X3	257	0	100%
X4	257	0	100%
X5	257	0	100%
Xtarget	257	0	100%

Dari hasil pemeriksaan dari Tabel 5.5 diketahui tidak terdapat adanya data *missing* atau keseluruhan datanya lengkap. Ketidakadanya data *missing* dapat dilihat dari hasil presentasi sebesar 100% ysg artinya baik untuk digunakan,

5.3.2 Normalisasi Data

Normalisasi data dilakukan untuk mengubah skala pengukuran data asli menjadi bentuk data sehingga skala data memiliki nilai yang sama. Pada penelitian ini menggunakan data *Min-Max Normalization* dengan menggunakan rumus Persamaan (3.3).

5.3.3 Pembagian Data *Training* dan Data *Testing*

Pembagian data menjadi dua bagian yaitu dimana terdapat data pelatihan yaitu disebut proses *training* dan data pengujian disebut proses *testing*. Dari pembagian kedua data memiliki fungsi masing-masing proses *training* merupakan proses pembelajaran dari sistem NN yang mengatur *input* serta bagaimana pemetaanna pada *output* sampai didapatkan model yang sesuai sedangkan, proses *testing* atau pengujian adalah pengujian ketelitian dari model yang diperoleh dari proses *training*. Hasil pembagian presentase pembagian data yang digunakan adalah sebagai berikut:

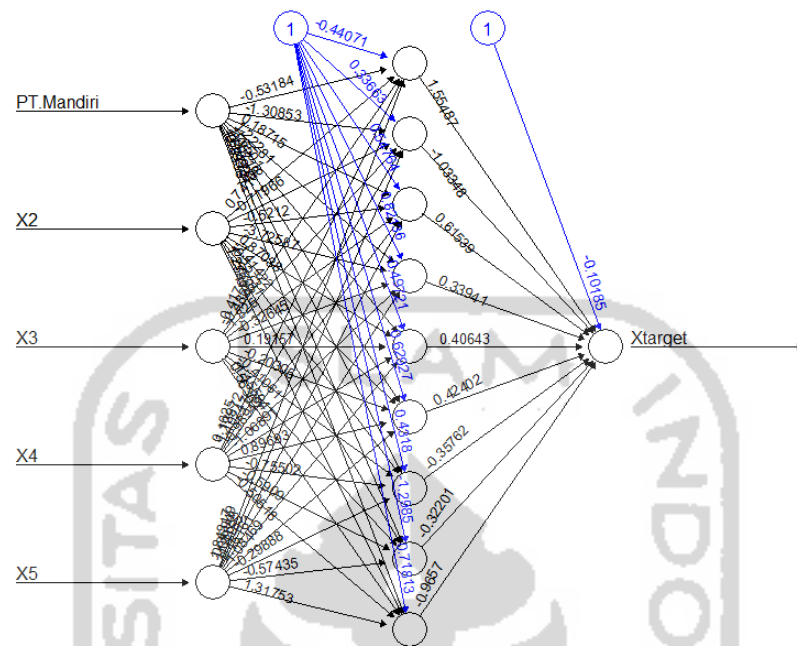
Tabel 5. 6 Pembagian Data *Training* dan *Testing*

Pembagian	Presentase	Total Data
Data <i>Training</i>	98%	252
Data <i>Testing</i>	2%	5
Total	100%	257

Pembagian data *training* harus lebih besar persentasenya dibandingkan data *testing* dikarenakan untuk mesin pembelajaran lebih terlatih dengan pola data latih. Hal ini berguna ketika mesin menghasilkan suatu model dan diberikan ke data *testing* untuk menghasilkan prediksi data *testing* yang lebih akurat.

5.3.4 Arsitektur Jaringan Syaraf Tiruan *Backpropagation*

Arsitektur jaringan pada jaringan syaraf tiruan (*Artificial Neural Network*) mempunyai arsitektur yang terdiri dari jumlah *neuron* pada tiap *layer*. Susunan jaringan pada kasus *Backpropagation* menggunakan *multilayer* yang terdiri dari jumlah unit *input*, jumlah unit *hidden layer* dan jumlah unit *output*. Menurut (Fausett, 1994) bahwa dengan jumlah *hidden layer* 1 saja cukup memadai untuk menghasilkan *output* yang sesuai target. Pada penelitian ini asitektur jaringan dengan menggunakan *neuron* untuk *input layer* berjumlah 5 *neuron* yang diasumsikan merupakan perwakilan dari 5 hari dikarenakan harga penutupan saham yang terjadi dalam seminggu sebanyak 5 hari, dan untuk *output layer* berjumlah 1 *neuron*, untuk *hidden layer* berjumlah 9 *neuron*. Berikut adalah merupakan arsitektur jaringan dari metode *Backpropagation*.



Gambar 5. 4 Rancangan Arsitektur Jaringan

Pada penelitian ini peneliti membandingkan jumlah untuk menentukan *hidden layer*, dengan menggunakan *hidden neuron* sebanyak 2 hingga *hidden neuron* sebanyak 10, bertujuan untuk mengetahui jumlah *neuron* yang terbaik dari metode *Backpropagation* berdasarkan dari hasil nilai MSE (*Mean square error*).

Tabel 5. 7 Uji Coba Jumlah Neuron Pada Hidden Layer

Jumlah Hidden Neuron	Nilai MSE
2	0.0186
3	0.0180
4	0.0185
5	0.0177
6	0.0180
7	0.0198
8	0.0184
9	0.0170
10	0.0182

Hasil dari uji coba jumlah *neuron* pada *hidden layer* menunjukkan bahwa jumlah *neuron* sebanyak 9 menghasilkan nilai *error* yang paling kecil dari hasil jumlah *neuron* yang lainnya. Dapat disimpulkan dengan menggunakan metode *Backpropagation* menggunakan *hidden layer* sebanyak 9 menghasilkan nilai *error* yang kecil sebesar 0.0170.

5.3.5 Inisialisasi Bobot

Inisialisasi bobot merupakan tahap awal sebelum melakukan prediksi harga saham penutupan dari PT. Bank Mandiri (Persero) Tbk, hasil data latih adalah inisialisasi bobot awal. Ada dua cara untuk menganalisis bobot, yaitu secara *random*. Inisialisasi acak merupakan cara yang paling sering digunakan dalam inisialisasi bobot. Pada inisialisasi bobot secara *random*, bobot di inisialisasi secara acak tanpa menggunakan faktor skala (Kholis & Rofii, 2017). Pada penelitian ini peneliti menggunakan dengan teknik *random*. Inisialisasi bobot awal yang akan masuk ke dalam *hidden layer* pertama *input layer* adalah sebagai berikut:

Tabel 5. 8 Bobot Awal *Hidden Layer*

Variabel	V[i,]	W[,j]								
		1	2	3	4	5	6	7	8	9
Bias	0	-0.5605	0.4609	0.4008	0.7014	-0.6250	0.4265	0.5540	-1.2654	0.7800
X1	1	-0.2302	-1.2651	0.1107	-0.4728	-1.6867	-0.2951	-0.0619	2.1690	-0.0834
X2	2	1.5587	-0.6869	-0.5558	-1.0678	0.8378	0.8951	-0.3060	1.2080	0.2533
X3	3	0.7051	-0.4457	1.7869	-0.2180	0.1534	0.8781	-0.3805	-1.1231	-0.2855
X4	4	0.1293	1.2241	0.4979	-1.0260	-1.1381	0.8216	-0.9647	-0.4029	-0.0429
X5	5	1.7151	0.3598	-1.9666	-0.7289	1.2538	0.6886	-0.2079	-0.4667	1.3686

Tabel 5. 9 Bobot Awal *Hidden Layer* ke *Output*

W[,j]	W[,k]
	1
0	-0.2257710
1	1.5164706
2	-1.5487528

W[j,]	W[,k]
	1
4	0.1238542
5	0.2159416
6	0.3796395
7	-0.5023235
8	-0.3332074
9	-1.0185754

5.3.6 Pelatihan Model *Backpropagation*

Setelah didapatkannya inialisasi bobot awal serta biasnya, maka akan dilanjutkan dengan proses pelatihan (*training*) dimana ada tiga fase proses pelatihan untuk algoritma *backpropagation* yaitu umpan maju (*feedforward*), propagasi balik (*backpropagation*), dan modifikasi bobot.

Fase I: Umpan maju (*feedforward*)

Menggunakan rumus pada Persamaan 3.10, berikut adalah hasil dari proses keluaran *neuron hidden layer* (Z_j) yang telah terboboti termasuk dengan biasnya, dengan menggunakan data *training* ke-1:

Tabel 5. 10 Sinyal Input dari *Input Layer* ke *Hidden Layer*

Z	$Z_{net j}$
1	2,141892446
2	-0,058271905
3	3,563432215
4	-2,175806424
5	-0,993619736
6	2,913112551
7	-0,810199923
8	-0,30701903
9	2,058014694

Setelah *hidden layer* menerima sinyal *input*, kemudian menggunakan fungsi aktivasi untuk menghitung sinyal keluarannya seperti di Persamaan 3.11 untuk diteruskan ke *output layer* dengan hasil sebagai berikut:

Tabel 5. 11 Sinyal *Output* di *Hidden Layer*

Z	Z_j
1	0,894908723
2	0,485436145
3	0,972439713
4	0,101944216
5	0,270197705
6	0,948490844
7	0,307847895
8	0,423842526
9	0,886754957

Operasi pada *output layer* (Y) dengan menggunakan Persamaan 3.12 hasil dari perhitungannya adalah sebagai berikut:

Tabel 5. 12 Sinyal *Input* dari *Hidden Layer* ke *Output Layer*

Y	Y_{net k}
1	1,35199169

Dengan menggunakan fungsi aktivasi pada *output layer* menggunakan Persamaan 3.13, dengan hasil perhitungannya adalah sebagai berikut:

Tabel 5. 13 Sinyal *Output* di *Output Layer*

Y	Y_k
1	0,794455055

Fase II: Backpropagation

Tahap sebelumnya sudah didapatkan *output* jaringan dan dibandingkan dengan *output* dengan target yang di *input*. Dari hal tersebut didapatkan *error* untuk memperbaiki bobot dan bias secara mundur. Menghitung faktor δ di unit keluaran Y,

hasil dari perhitungan dengan menggunakan Persamaan 3.14 hasil faktor kesalahan δ_k sebesar -0.129731508

Faktor kesalahan δ_k digunakan untuk memperbaiki bobot (W_{jk}) dan bias (W_{ok}) di lapisan *hidden layer*, dengan perubahan bobot dengan $\alpha = 0.01$ dengan menggunakan Persamaan 3.15 hasil perhitungan adalah sebagai berikut :

Tabel 5. 14 Koreksi Bobot dan Bias di *Hidden Layer* Terhadap *Output Layer*

$\Delta W_{[j]}$	$\Delta W_{[k]}$
	1
0	-0,001297315
1	-0,001160979
2	-0,000629764
3	-0,001261561
4	-0,000132254
5	-0,000350532
6	-0,001230491
7	-0,000399376
8	-0,000549857
9	-0,001150401

Menghitung penjumlahan kesalahan dari unit tersembunyi, karena jaringan hanya memiliki satu unit *output* maka dengan menggunakan Persamaan 3.17, hasil yang didapatkan adalah sebagai berikut:

Tabel 5. 15 Faktor Kesalahan di Unit Tersembunyi

Z_j	$\delta_{net j}$
1	-0,196734018
2	0.200922036
3	-0.07584282
4	-0.016067792
5	-0.028014429
6	-0.049251205
7	0.065167185
Z_j	$\delta_{net j}$

8	0.04322750
9	0.132141323

Input dari faktor kesalahan di unit tersembunyi, dan akan menggunakan fungsi aktivasi dengan Persamaan 3.18, hasil perhitungannya adalah sebagai berikut:

Tabel 5. 16 Faktor Kesalahan di Unit Tersembunyi

Z_j	δ_j
1	-0.018502264
2	0.050187892
3	-0.002032642
4	-0.001471032
5	-0.005524191
6	-0.002406215
7	0.013885665
8	0.010556157
9	0.013269711

Didapatkan hasil dari faktor kesalahan δ_j dengan menggunakan fungsi aktivasi, kemudian dengan menghitung suku perubahan bobot ke unit tersembunyi dengan menggunakan Persamaan 3.19, hasil perhitungannya adalah sebagai berikut:

Tabel 5. 17 Koreksi Bobot dan Bias di *Input Layer* Terhadap *Hidden Layer*

$V[i,]$	$V[,j]$								
	1	2	3	4	5	6	7	8	9
0	-1.850E-04	5.019E-04	-2.033E-05	-1.471E-05	-5.524E-05	-2.406E-05	1.389E-04	1.056E-04	1.327E-04
1	-1.388E-04	3.764E-04	-1.524E-05	-1.103E-05	-4.143E-05	-1.805E-05	1.041E-04	7.917E-05	9.952E-05
2	-1.490E-04	4.043E-04	-1.637E-05	-1.185E-05	-4.450E-05	-1.938E-05	1.112E-04	8.504E-05	1.069E-04
3	-1.490E-04	4.043E-04	-1.637E-05	-1.185E-05	-4.450E-05	-1.938E-05	1.112E-04	8.504E-05	1.069E-04
4	-1.568E-04	4.252E-04	-1.722E-05	-1.246E-05	-4.680E-05	-2.039E-05	1.176E-04	8.943E-05	1.124E-04
5	-1.568E-04	4.252E-04	-1.722E-05	-1.246E-05	-4.680E-05	-2.039E-05	1.176E-04	8.943E-05	1.124E-04

Fase III: Modifikasi bobot dan bias (*Adjustment*)

Setiap unit *output* akan mempebaharui bias dan bobot dari setiap *hidden* unit, demikian pula untuk *hidden* unit akan memperbaharui bias dan bobot dari setiap unit, dengan menggunakan Persamaan dari 3.21 dan 3.22, dimana didapatkan bobot dan bias akhir dengan satu kali langkah hasil perhitungannya adalah sebagai berikut:

Tabel 5. 18 Bobot dan Bias Akhir pada *Input Layer* Terhadap *Hidden Layer*


Variabel	V[i,]	V[j]								
		1	2	3	4	5	6	7	8	9
Bias	0	-0.4407	0.3366	0.5476	0.8214	-0.4972	0.6293	0.4318	-1.2985	0.7181
X1	1	-0.5318	-1.3085	0.1872	1.2228	-1.6501	1.0572	-0.1092	1.6077	-0.8538
X2	2	0.7417	-0.7197	-0.5212	-3.7259	0.8704	-2.4142	-0.2273	1.2780	1.7419
X3	3	-0.4176	-0.4826	1.8250	-0.3265	0.1916	-0.2030	-0.4106	-1.1559	0.5637
X4	4	0.1625	1.1397	1.4025	-0.9895	-1.0689	0.8969	-0.7550	-0.5909	-0.5052
X5	5	1.8432	-0.3695	1.0565	-1.4155	2.1616	1.0847	-0.2989	-0.5744	1.3175

Tabel 5. 19 Bobot dan Bias Akhir pada *Hidden Layer* Terhaap *Output Layer*

$W_{[j]}$	$W_{[k]}$
	1
0	-0.1018452
1	1.5548719
2	-1.0334755
3	0.6153911
4	0.3394103
5	0.4064277
6	0.4240200
7	-0.3576217
8	-0.3220142
9	-0.9656994

5.3.7 Hasil Prediksi

Hasil dari prediksi data penutupan saham harian dari PT. Bank Mandiri (Persero) Tbk dalam peramalan menggunakan metode *Backpropagation*. Dengan menggunakan perbandingan data asli dan prediksi untuk melihat kemiripan dan memperhitungkan nilai kesalahan pada peramalan. Pengujian hasil prediksi ini menggunakan data *training* atau data pelatihan adalah sebagai berikut:



Gambar 5. 5 Plot Data Asli dan Data Prediksi Metode *Backpropagation*

Dapat dilihat dari Gambar 5.5 yang merupakan hasil plot dari perbandingan data asli dan data prediksi pada metode *Backpropagation*. Terdapat sumbu x yang merupakan waktu dari data saham sedangkan, sumbu y merupakan jumlah dari data saham harian PT. Bank Mandiri (Persero) Tbk. Garis berwarna hitam yang merupakan dari data asli sedangkan, garis berwarna biru yang merupakan dari data hasil prediksi. Dari Gambar 5.5 yang merupakan plot perbandingan data asli dan data prediksi. Dapat dilihat dari hasil plot perbandingan antara data asli dan prediksi dimana garis dari data prediksi yang tidak jauh beda dengan data asli, atau data prediksi mengikuti pola dari data asli. Untuk hasil lebih jelasnya berikut hasil perbandingan data asli dan data prediksi pada proses data *training*:

Tabel 5. 20 Data Aktual Dan Prediksi Metode *Backpropagation*

Tanggal	Data Aktual	Data Prediksi
21/01/2019	7,800	7,849
22/01/2019	7,750	7,785
23/01/2019	7,475	7,746
24/01/2019	7,475	7,748

Data ke	Data Aktual	Data Prediksi
25/01/2019	7,375	7,484
...
07/01/2020	7,600	7,600
08/01/2020	7,500	7,606
09/01/2020	7,700	7,501
10/01/2020	7,725	7,701
13/01/2020	7,725	7,700

Dari hasil prediksi harga penutupan saham harian PT. Bank Mandiri (Persero) Tbk dengan menggunakan metode *Backpropagation* menggunakan pelatihan data memberikan nilai *Mean square error* (MSE) sebesar 0.0170. Kemudian didapatkan juga nilai *Mean Absolute Percentage Error* (MAPE) sebesar 1.628%

5.4 Perbandingan Metode ELM dan *Backpropagation*

Untuk suatu hasil peramalan adanya evaluasi hasil peramalan, dengan menggunakan ukuran kesalahan peramalan. Hasil peramalan yang terbaik memiliki nilai kesalahan peramalan yang terkecil. Melakukan perbandingan dari kedua metode yaitu metode *Extreme Learning Machine* dengan metode *Backpropagation* adalah dengan melakukan perbandingan dari tingkat keakuratan metode, dimana dengan menggunakan nilai *Mean Absolute Percentage Error* (MAPE).

4.4.1 MAPE Prediksi Metode *Extreme Learning Machine*

Pengujian hasil prediksi ini menggunakan data *testing* atau data pengujian pada metode *Extreme Learning Machine* dengan presentase data pengujian sebesar 2% dari jumlah data yang digunakan yaitu sebanyak 5 data uji hasil perhitungannya adalah sebagai berikut:

$$MAPE = 100\% \frac{1}{5} \sum_{i=1}^n \left| \frac{7,600 - 7,597}{7,600} \right| + \left| \frac{7,500 - 7,603}{7,500} \right| + \left| \frac{7,700 - 7,599}{7,700} \right| + \left| \frac{7,725 - 7,605}{7,725} \right| + \left| \frac{7,725 - 7,595}{7,725} \right|$$

$$= 100\% \frac{1}{5} \times 0.0596$$

$$= 1.192\%$$

Tabel 5. 21 Hasil Nilai MAPE Metode ELM

Data ke	Data Aktual	Data Prediksi	Hasil MAPE
1	7,600	7,597	1.192%
2	7,500	7,603	
3	7,700	7,599	
4	7,725	7,605	
5	7,725	7,595	

4.4.2 MAPE Prediksi Metode *Backpropagation*

Pengujian hasil prediksi ini menggunakan data *testing* atau data pengujian pada metode *Backpropagation* dengan presentase data pengujian sebesar 2% dari jumlah data yang digunakan yaitu sebanyak 5 data uji hasil perhitungannya adalah sebagai berikut:

$$MAPE = 100\% \frac{1}{5} \sum_{i=1}^n \left| \frac{7,550 - 7,709}{7,550} \right| + \left| \frac{7,725 - 7,545}{7,725} \right| + \left| \frac{7,625 - 7,729}{7,625} \right| + \left| \frac{7,700 - 7,624}{7,700} \right| + \left| \frac{7,800 - 7,695}{7,800} \right|$$

$$= 100\% \frac{1}{5} \times 0.0596 = 1.627\%$$

Tabel 5. 22 Hasil Nilai MAPE Metode *Backpropagation*

Data Ke	Data Aktual	Data Prediksi	Hasil MAPE
1	7,550	7,709	1.627%
2	7,725	7,545	
3	7,625	7,729	
4	7,700	7,624	
5	7,800	7,695	

Dari hasil perhitungan nilai MAPE pada kedua metode didapatkan hasil pada metode *Extreme Learning Machine* nilai *Mean Absolute Percentage Error* sebesar 1.192% sedangkan, pada metode *Backpropagation* proses *feedforward* dan *backward* hasil perhitungan dari nilai *Mean Absolute Percentage Error* sebesar 1.627% dimana hasil peramalan menurut Tabel 3.1 interpretasi nilai MAPE termasuk ke kemampuan peramalan sangat baik karena berada pada rentang kurang dari 10% yang berarti cukup baik saat sistem melakukan pengujian.

Setelah didapatkan kedua nilai MAPE kemudian akan dilakukan perbandingan kedua metode berdasarkan hasil nilai minimum MAPE. Berikut adalah hasil perbandingan kedua metode:

Tabel 5. 23 Hasil Perbandingan Metode

Metode	MAPE <i>Training</i>	MAPE <i>Testing</i>
<i>Extreme Learning Machine</i>	1.243%	1.192%
<i>Backpropagation</i>	1.198%	1.627%

Dapat dilihat dari Tabel 5.23 hasil perbandingan nilai *Mean Absolute Percentage Error* pada kedua metode didapatkan metode *Extreme Learning Machine* nilai MAPE pada data *training* sebesar 1.243%, sedangkan pada metode *Backpropagation* nilai MAPE pada data *training* sebesar 1.198% dimana hasil menunjukkan bahwa presentase metode *Backpropagation* pada data *training* tingkat kesalahannya lebih kecil daripada metode ELM. Pada metode *Extreme Learning Machine* nilai MAPE pada data *testing* sebesar 1.192%, sedangkan pada metode *Backpropagation* nilai MAPE pada data *testing* sebesar 1.627% dimana hasil menunjukkan bahwa presentase metode ELM pada data *testing* tingkat kesalahannya lebih kecil daripada metode *Backpropagation*.

BAB VI PENUTUP

6.1 Kesimpulan

Berdasarkan dari rumusan masalah dan hasil penelitian yang sudah dijelaskan di bab pembahasan, maka dapat diperoleh kesimpulan sebagai berikut:

1. Gambaran umum dari harga penutupan saham PT. Bank Mandiri (Persero) Tbk pada periode 14 Januari 2019 sampai dengan 13 Januari 2020, terdapat harga saham terendah yaitu sebesar 6,350 yang terjadi pada tanggal 7 Oktober 2019 dan harga penutupan saham tertinggi yaitu 8,150 yang terjadi pada tanggal 15 Juli 2019. Kemudian rata-rata dari harga penutupan saham yaitu 7,370 per hari. Harga penutupan saham PT. Bank Mandiri cenderung memiliki pola data *trend*, dan tidak memiliki kenaikan atau penurunan yang sangat drastis.
2. Hasil prediksi menggunakan data saham harian periode 14 Januari 2019 sampai dengan 13 Januari 2020 dengan metode *Extreme Learning Machine*
3. didapatkan hasil yaitu pada tanggal 21 Januari 2019 hasil prediksi sebesar 7,818 dengan data aktual sebesar 7,800, pada tanggal 22 Januari 2019 hasil prediksi sebesar 7,772 dengan data aktual sebesar 7,750, pada tanggal 23 Januari 2019 hasil prediksi sebesar 7,725 dengan data aktual sebesar 7,475, dan sampai dengan tanggal 13 Januari 2020 hasil prediksi sebesar 7,700 dengan data aktual sebesar 7,725. Kemudian pada metode *Backpropagation* didapatkan hasil yaitu pada tanggal 21 Januari 2019 hasil prediksi sebesar 7,849 dengan data aktual sebesar 7,800, pada tanggal 22 Januari 2019 hasil prediksi sebesar 7,785 dengan data aktual sebesar 7,750, pada tanggal 23 Januari 2019 hasil prediksi sebesar 7,746 dengan data aktual sebesar 7,475, dan sampai dengan tanggal 13 Januari 2020 hasil prediksi sebesar 7,700 dengan data aktual sebesar 7,725.

4. Hasil perbandingan metode ELM dan *Backpropagation* jika dibandingkan dengan nilai *Mean Absolute Percentage Error* pada kedua metode didapatkan metode *Extreme Learning Machine* nilai MAPE pada data *training* sebesar 1.243%, sedangkan pada metode *Backpropagation* nilai MAPE pada data *training* sebesar 1.198% dimana hasil menunjukkan bahwa presentase metode *Backpropagation* pada data *training* tingkat kesalahannya lebih kecil daripada metode ELM. Pada metode *Extreme Learning Machine* nilai MAPE pada data *testing* sebesar 1.192%, sedangkan pada metode *Backpropagation* nilai MAPE pada data *testing* sebesar 1.627% dimana hasil menunjukkan bahwa presentase metode ELM pada data *testing* tingkat kesalahannya lebih kecil daripada metode *Backpropagation*.

6.2 Saran

Adapun saran yang dapat diberikan dalam penelitian ini yaitu:

1. Bagi investor-investor bisa menggunakan metode *Extreme Learning Machine* dan metode *Backpropagation*. Untuk memprediksi harga saham, dan bagaimana prospek investasi saham perusahaan di masa mendatang. Prediksi harga saham bisa digunakan untuk mengantisipasi penyimpangan harga saham dan membantu investor dalam pengambilan keputusan.
2. Peneliti mengkaji tentang *Extreme Learning Machine* dan metode *Backpropagation* dalam bidang peramalan harga saham. Penelitian selanjutnya masih dapat mengembangkan lagi pada bidang ilmu lain minsalkan menggunakan pengembangan metode dari *Extreme Learning Machine* contohnya *Genetic Algorithm-Extrme Learning Mahine (GA-ELM)*, *Particle Swarm Optimization- Extrme Learning Mahine (PSO-ELM)*, dan *Ant Colony Optimization- Extrme Learning Mahine (ACO-ELM)* mengingat cakupan analisis peramalan yang sangat luas.

DAFTAR PUSTAKA

- Agustina, I. D. (2010). *Penerapan Metode Extreme Learning Machine untuk Peramalan Permintaan*. Institut Teknologi Sepuluh November Surabaya: Tugas Akhir.
- Aina, I. Q. (2018). *Implementasi Artificial Neural Network (ANN) Dengan Algoritma Backpropagation Untuk Memprediksi Volume Penjualan Di Bukalapak*. Yogyakarta: Tugas Akhir.
- Amiroch, S. (2015). Prediksi Harga Saham Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Unisda Journal of Mathematics and Computer Science (UJMC)*, No 1, Hal. 57-84.
- Asri, M. (1986). *Marketing*. Yogyakarta: BPFE.
- Boedijoewono, N. (2012). *Pengantar Statistika Ekonomi dan Bisnis*. Yogyakarta: Unit Penerbitan dan Percetakan (UPP) STIM YKPN.
- Danareksaonline. (2014). *Edukasi Pasar Modal*. Retrieved from Saham: <http://dmia.danareksaonline.com/Edukasi/Saham>
- Darmadji, T., & Fakhruddin, H. M. (2012). *Pasar Modal Indonesia Pendekatan*. Jakarta: Salemba Empat.
- Fahmi, I. (2012). *Analisis Laporan Keuangan*. Cetakan Ke-2. Bandung: Alfabeta.
- Fausett, L. (1994). *Fundamentals of Neural Networks Architectures, Algorithms and Applications*. New Jersey: Prentice Hall.
- Ginanto, N. (2012, November 14). *Backpropagation*. Retrieved from wordpress.com: <https://novikaginanto.wordpress.com/2012/11/14/backpropagation/>

- Giusti, A., Widodo, A. W., & Adinugroho, S. (2018). Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 2, No. 8.
- Heizer, J., & Render, B. (2006). *Manajemen Operasi edisi 7*. Jakarta: Salemba.
- Hermawan, A. (2006). *Pengantar Jaringan Syaraf Tiruan, Teori, dan Aplikasi*. Yogyakarta: Andi.
- Huang, G.-B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 489-501.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. OTexts.
- Irwansyah, E., & Faisal, M. (2015). *Advance Clustering Teori dan Aplikasi*. Yogyakarta: Deepublish.
- Jumingan. (2009). *Studi Kelayakan Bisnis – Teori dan Pembuatan Proposal*. Jakarta: Bumi Aksara.
- Kholis, I., & Rofii, A. (2017). Analisis Variasi Parameter Backpropagation Artificial Neural Network Pada Sistem Pengenalan Wajah Berbasis Principal Component Anaysis. *Ejournal Kajian Teknik Elektro*, Vol.2 No.1.
- Kusumadewi, F. (2014). *Peramalan Harga Emas Menggunakan Feedforward Neural Network Dengan Algoritma Backpropagation*. Yogyakarta: Tugas Akhir.
- Kusumadewi, S. (2003). *Artificial Intelligence (Teknik dan Aplikasinya)*. Yogyakarta: Graha Ilmu.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan Aplikasi Peramalan*. Jakarta: Binarupa Aksara.

- Martono, W. H., & Hartanti, D. (2015). Penggunaan Jaringan Syaraf Tiruan Dengan Metode Backpropagation Dalam Memprediksi Indeks Harga Saham Gabungan (IHSG). *Jurnal Teknologi dan Informasi (JATI)*, Vol 5 No 1 .
- Moreno, J. M., Pol, A. P., Abad , A. S., & Blasco, B. C. (2013). Using the R-MAPE Index as a Resistant Measure of Forecast Accuracy. *Psicothema*, Vol.25, No.4, hal. 500-506.
- Mudjiyono. (2012). Investasi Dalam Saham & Obligasi dan Meminimalisasi Risiko Sekuritas Pada Pasar Modal Indonesia. *Jurnal STIE Semarang*, Vol. 4, No. 2, Edisi Juni 2012 (ISSN : 2252-7826). STIE Semarang.
- Nasution, D. A., Khotimah, H. H., & Chamidah, N. (2019). Perbandingan Normalisasi Data Untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Journal of Computer Engineering System and Science*, Vol. 4 No. 1 Januari 2019.
- Nur'afifah. (2011). *Analisis Metode Backpropagation Untuk Memprediksi Indeks Harga Saham Pada Kelompok Indeks Bisnis-27*. Jakarta: Tugas Akhir.
- Pratama, M. I., Adikara, P. P., & Adinugroho, S. (2018). Peramalan Harga Saham Menggunakan Metode Extreme Learning Machine (ELM) Studi Kasus Saham Bank Mandiri. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5009.
- Puspitaningrum, D. (2006). *Pengantar Jaringan Syaraf Tiruan*. Yogyakarta: Andi Offset.
- Riyanto, E. (2017). Peramalan Harga Saham Menggunakan Jaringan Syaraf Tiruan Secara Supervised Learning Dengan Algoritma Backpropagation. *Jurnal Informatika Upgris*, Vol. 3, No. 2.
- Rosadi, D. (2006). *Pengantar Analisis Runtun Waktu (Diktat Kuliah)*. Yogyakarta: Fakultas Ilmu Matematika dan Pengetahuan Alam Universitas Gajah Mada.

- Sanudin, Y. A., & Nugraha, J. (2019). Penerapan Metode Extreme Learning Machine Untuk Meramalkan Wisatawan Mancanegara di Sulawesi Utara. *Prosiding Sendika*, Vol 5, No 2.
- Saputra, J. (2019). *Perbandingan Metode Fuzzy Time Series Markov Chain Dan Extreme Learning Machine Pada Peramalan Data Penumpang Pesawat Manca-Negara Di Bandara Soekarno Hatta Dan Ngurah Rai*. Yogyakarta: Tugas Akhir.
- Saputri, E. A., & Ekojono. (2018). Prediksi Volume Impor Beras Nasional Menggunakan Jaringan Saraf Tiruan Metode ELM (Extreme Learning Machine). *SENTIA*, Vol. 10 No.1.
- Siang, J. J. (2009). *Jaringan Syaraf Tiruan & Pemogramannya Menggunakan Matlab*. Yogyakarta: Penerbit Andi.
- Situmorang, P., Mahardhika, J., & Listiyarini, T. (2010). *Jurus-Jurus Berinvestasi Saham untuk Pemula*. Jakarta: Trans Media.
- Supriyadi. (2018). *Analisis Klasifikasi Genre Musik Pop dan Klasik pada Layanan Streaming Musik Spotify Menggunakan Artificial Neural Network (ANN)*. Yogyakarta: Tugas Akhir.
- Suyanto. (2011). *Artificial Intelligence (Edisi Revisi)*. Bandung: Informatika Bandung.
- Utami, N. W. (2019, Oktober 2). *ajaib.co.id*. Retrieved from Menabung?Investasi?Saham Mandiri Bisa Ubah Persepsimu: <https://ajaib.co.id/menabung-atau-investasi-harga-saham-mandiri-bisa-mengubah-persepsimu/>
- Walpole, R. E., & Myers, R. H. (1995). *Ilmu Peluang dan Statistik untuk Insinyur dan*. Bandung: ITB.

Walpole, R. E., Myers, R. H., Myers, S. L., & Ye, K. (2011). *Probability & Statistics for Engineers & Scientists 9th Ed.* USA: Person.

Winarno, W. W. (2007). *Analisis Ekonometrika dan Statistika dengan EViews.* Yogyakarta: UPP STIM YKPN.




LAMPIRAN

Lampiran 1 Data Saham PT. Bank Mandiri (Persero) Tbk

Tanggal	PT Mandiri	Tanggal	PT Mandiri	Tanggal	PT Mandiri
14/01/2019	7,700	14/05/2019	7,450	11/09/2019	7,150
15/01/2019	7,800	15/05/2019	7,425	12/09/2019	7,150
16/01/2019	7,800	16/05/2019	7,350	13/09/2019	7,200
17/01/2019	7,875	17/05/2019	7,075	16/09/2019	7,000
18/01/2019	7,875	20/05/2019	7,225	17/09/2019	6,975
21/01/2019	7,800	21/05/2019	7,250	18/09/2019	7,200
22/01/2019	7,750	22/05/2019	7,300	19/09/2019	7,100
23/01/2019	7,475	23/05/2019	7,575	20/09/2019	7,075
24/01/2019	7,475	24/05/2019	7,700	23/09/2019	7,000
25/01/2019	7,375	27/05/2019	7,725	24/09/2019	6,950
28/01/2019	7,175	28/05/2019	7,375	25/09/2019	6,900
29/01/2019	7,125	29/05/2019	7,550	26/09/2019	7,100
30/01/2019	7,250	30/05/2019	7,550	27/09/2019	6,975
31/01/2019	7,450	31/05/2019	7,675	30/09/2019	6,975
01/02/2019	7,600	03/06/2019	7,675	01/10/2019	6,900
04/02/2019	7,350	04/06/2019	7,675	02/10/2019	6,525
05/02/2019	7,350	05/06/2019	7,675	03/10/2019	6,400
06/02/2019	7,475	06/06/2019	7,675	04/10/2019	6,400
07/02/2019	7,550	07/06/2019	7,675	07/10/2019	6,350
08/02/2019	7,575	10/06/2019	7,850	08/10/2019	6,500
11/02/2019	7,625	11/06/2019	7,875	09/10/2019	6,425
12/02/2019	7,425	12/06/2019	7,875	10/10/2019	6,525
13/02/2019	7,250	13/06/2019	7,825	11/10/2019	6,550
14/02/2019	7,175	14/06/2019	7,825	14/10/2019	6,600
15/02/2019	7,175	17/06/2019	7,800	15/10/2019	6,575
18/02/2019	7,275	18/06/2019	7,850	16/10/2019	6,625
19/02/2019	7,200	19/06/2019	7,975	17/10/2019	6,700
20/02/2019	7,100	20/06/2019	7,950	18/10/2019	6,775
21/02/2019	7,325	21/06/2019	7,975	21/10/2019	6,800
22/02/2019	7,100	24/06/2019	7,975	22/10/2019	6,825
25/02/2019	7,250	25/06/2019	7,950	23/10/2019	7,075
26/02/2019	7,275	26/06/2019	7,950	24/10/2019	7,225

Tanggal	PT Mandiri	Tanggal	PT Mandiri	Tanggal	PT Mandiri
27/02/2019	7,200	27/06/2019	8,000	25/10/2019	7,000
28/02/2019	7,125	28/06/2019	8,025	28/10/2019	7,000
01/03/2019	7,175	01/07/2019	8,000	29/10/2019	7,100
04/03/2019	7,100	02/07/2019	8,025	30/10/2019	7,025
05/03/2019	6,950	03/07/2019	8,025	31/10/2019	7,025
06/03/2019	7,075	04/07/2019	8,025	01/11/2019	6,975
07/03/2019	7,075	05/07/2019	7,825	04/11/2019	6,875
08/03/2019	6,900	08/07/2019	7,875	05/11/2019	7,200
11/03/2019	6,850	09/07/2019	7,900	06/11/2019	6,975
12/03/2019	6,725	10/07/2019	7,950	07/11/2019	7,000
13/03/2019	6,700	11/07/2019	8,000	08/11/2019	7,100
14/03/2019	6,900	12/07/2019	8,075	11/11/2019	7,050
15/03/2019	7,100	15/07/2019	8,150	12/11/2019	7,025
18/03/2019	7,100	16/07/2019	8,075	13/11/2019	6,875
19/03/2019	7,375	17/07/2019	7,975	14/11/2019	6,875
20/03/2019	7,400	18/07/2019	7,850	15/11/2019	6,950
21/03/2019	7,475	19/07/2019	7,875	18/11/2019	6,975
22/03/2019	7,450	22/07/2019	7,775	19/11/2019	7,150
25/03/2019	7,175	23/07/2019	7,700	20/11/2019	7,100
26/03/2019	7,300	24/07/2019	7,700	21/11/2019	7,175
27/03/2019	7,225	25/07/2019	7,800	22/11/2019	7,075
28/03/2019	7,375	26/07/2019	7,750	25/11/2019	6,975
29/03/2019	7,475	29/07/2019	7,800	26/11/2019	6,925
01/04/2019	7,500	30/07/2019	7,950	27/11/2019	6,900
02/04/2019	7,425	31/07/2019	7,975	28/11/2019	6,775
03/04/2019	7,425	01/08/2019	7,775	29/11/2019	6,975
04/04/2019	7,675	02/08/2019	7,675	02/12/2019	7,100
05/04/2019	7,550	05/08/2019	7,425	03/12/2019	7,175
08/04/2019	7,500	06/08/2019	7,250	04/12/2019	7,075
09/04/2019	7,675	07/08/2019	7,350	05/12/2019	7,175
10/04/2019	7,550	08/08/2019	7,500	06/12/2019	7,175
11/04/2019	7,400	09/08/2019	7,450	09/12/2019	7,250
12/04/2019	7,325	12/08/2019	7,400	10/12/2019	7,375
15/04/2019	7,350	13/08/2019	7,350	11/12/2019	7,350
16/04/2019	7,625	14/08/2019	7,500	12/12/2019	7,300
17/04/2019	7,625	15/08/2019	7,400	13/12/2019	7,375
18/04/2019	7,800	16/08/2019	7,375	16/12/2019	7,350

Tanggal	PT Mandiri	Tanggal	PT Mandiri	Tanggal	PT Mandiri
19/04/2019	7,800	19/08/2019	7,350	17/12/2019	7,350
22/04/2019	7,750	20/08/2019	7,375	18/12/2019	7,525
23/04/2019	7,675	21/08/2019	7,225	19/12/2019	7,600
24/04/2019	7,675	22/08/2019	7,225	20/12/2019	7,700
25/04/2019	7,650	23/08/2019	7,175	23/12/2019	7,725
26/04/2019	7,725	26/08/2019	7,050	26/12/2019	7,800
29/04/2019	7,775	27/08/2019	7,025	27/12/2019	7,750
30/04/2019	7,725	28/08/2019	7,050	30/12/2019	7,675
01/05/2019	7,725	29/08/2019	7,075	02/01/2020	7,750
02/05/2019	7,700	30/08/2019	7,250	03/01/2020	7,725
03/05/2019	7,650	02/09/2019	7,175	06/01/2020	7,600
06/05/2019	7,525	03/09/2019	6,900	07/01/2020	7,600
07/05/2019	7,650	04/09/2019	6,925	08/01/2020	7,500
08/05/2019	7,525	05/09/2019	6,975	09/01/2020	7,700
09/05/2019	7,500	06/09/2019	7,050	10/01/2020	7,725
10/05/2019	7,475	09/09/2019	6,975	13/01/2020	7,725
13/05/2019	7,525	10/09/2019	7,050		



Lampiran 2 Hasil Training Metode Extreme Learning Machine

Data	Node Input					
i	Y	X₁	X₂	X₃	X₄	X₅
1	0.48889	0.55556	0.55556	0.48889	0.48889	0.40000
2	0.44444	0.48889	0.55556	0.55556	0.48889	0.48889
3	0.20000	0.44444	0.48889	0.55556	0.55556	0.48889
4	0.20000	0.20000	0.44444	0.48889	0.55556	0.55556
5	0.11111	0.20000	0.20000	0.44444	0.48889	0.55556
6	-0.06667	0.11111	0.20000	0.20000	0.44444	0.48889
7	-0.11111	-0.06667	0.11111	0.20000	0.20000	0.44444
8	0.00000	-0.11111	-0.06667	0.11111	0.20000	0.20000
9	0.17778	0.00000	-0.11111	-0.06667	0.11111	0.20000
10	0.31111	0.17778	0.00000	-0.11111	-0.06667	0.11111
11	0.08889	0.31111	0.17778	0.00000	-0.11111	-0.06667
12	0.08889	0.08889	0.31111	0.17778	0.00000	-0.11111
13	0.20000	0.08889	0.08889	0.31111	0.17778	0.00000
14	0.26667	0.20000	0.08889	0.08889	0.31111	0.17778
15	0.28889	0.26667	0.20000	0.08889	0.08889	0.31111
16	0.33333	0.28889	0.26667	0.20000	0.08889	0.08889
17	0.15556	0.33333	0.28889	0.26667	0.20000	0.08889
18	0.00000	0.15556	0.33333	0.28889	0.26667	0.20000
19	-0.06667	0.00000	0.15556	0.33333	0.28889	0.26667
20	-0.06667	-0.06667	0.00000	0.15556	0.33333	0.28889
21	0.02222	-0.06667	-0.06667	0.00000	0.15556	0.33333
22	-0.04444	0.02222	-0.06667	-0.06667	0.00000	0.15556
23	-0.13333	-0.04444	0.02222	-0.06667	-0.06667	0.00000
24	0.06667	-0.13333	-0.04444	0.02222	-0.06667	-0.06667
25	-0.13333	0.06667	-0.13333	-0.04444	0.02222	-0.06667
26	0.00000	-0.13333	0.06667	-0.13333	-0.04444	0.02222
27	0.02222	0.00000	-0.13333	0.06667	-0.13333	-0.04444
28	-0.04444	0.02222	0.00000	-0.13333	0.06667	-0.13333
29	-0.11111	-0.04444	0.02222	0.00000	-0.13333	0.06667
30	-0.06667	-0.11111	-0.04444	0.02222	0.00000	-0.13333
31	-0.13333	-0.06667	-0.11111	-0.04444	0.02222	0.00000
32	-0.26667	-0.13333	-0.06667	-0.11111	-0.04444	0.02222
33	-0.15556	-0.26667	-0.13333	-0.06667	-0.11111	-0.04444
34	-0.15556	-0.15556	-0.26667	-0.13333	-0.06667	-0.11111

Data	Y	X ₁	X ₂	X ₃	X ₄	X ₅
35	-0.31111	-0.15556	-0.15556	-0.26667	-0.13333	-0.06667
36	-0.35556	-0.31111	-0.15556	-0.15556	-0.26667	-0.13333
37	-0.46667	-0.35556	-0.31111	-0.15556	-0.15556	-0.26667
38	-0.48889	-0.46667	-0.35556	-0.31111	-0.15556	-0.15556
39	-0.31111	-0.48889	-0.46667	-0.35556	-0.31111	-0.15556
40	-0.13333	-0.31111	-0.48889	-0.46667	-0.35556	-0.31111
41	-0.13333	-0.13333	-0.31111	-0.48889	-0.46667	-0.35556
42	0.11111	-0.13333	-0.13333	-0.31111	-0.48889	-0.46667
43	0.13333	0.11111	-0.13333	-0.13333	-0.31111	-0.48889
44	0.20000	0.13333	0.11111	-0.13333	-0.13333	-0.31111
45	0.17778	0.20000	0.13333	0.11111	-0.13333	-0.13333
46	-0.06667	0.17778	0.20000	0.13333	0.11111	-0.13333
47	0.04444	-0.06667	0.17778	0.20000	0.13333	0.11111
48	-0.02222	0.04444	-0.06667	0.17778	0.20000	0.13333
49	0.11111	-0.02222	0.04444	-0.06667	0.17778	0.20000
50	0.20000	0.11111	-0.02222	0.04444	-0.06667	0.17778
51	0.22222	0.20000	0.11111	-0.02222	0.04444	-0.06667
52	0.15556	0.22222	0.20000	0.11111	-0.02222	0.04444
53	0.15556	0.15556	0.22222	0.20000	0.11111	-0.02222
54	0.37778	0.15556	0.15556	0.22222	0.20000	0.11111
55	0.26667	0.37778	0.15556	0.15556	0.22222	0.20000
56	0.22222	0.26667	0.37778	0.15556	0.15556	0.22222
57	0.37778	0.22222	0.26667	0.37778	0.15556	0.15556
58	0.26667	0.37778	0.22222	0.26667	0.37778	0.15556
59	0.13333	0.26667	0.37778	0.22222	0.26667	0.37778
60	0.06667	0.13333	0.26667	0.37778	0.22222	0.26667
61	0.08889	0.06667	0.13333	0.26667	0.37778	0.22222
62	0.33333	0.08889	0.06667	0.13333	0.26667	0.37778
63	0.33333	0.33333	0.08889	0.06667	0.13333	0.26667
64	0.48889	0.33333	0.33333	0.08889	0.06667	0.13333
65	0.48889	0.48889	0.33333	0.33333	0.08889	0.06667
66	0.44444	0.48889	0.48889	0.33333	0.33333	0.08889
67	0.37778	0.44444	0.48889	0.48889	0.33333	0.33333
68	0.37778	0.37778	0.44444	0.48889	0.48889	0.33333
69	0.35556	0.37778	0.37778	0.44444	0.48889	0.48889
70	0.42222	0.35556	0.37778	0.37778	0.44444	0.48889
71	0.46667	0.42222	0.35556	0.37778	0.37778	0.44444

Data	Y	X₁	X₂	X₃	X₄	X₅
72	0.42222	0.46667	0.42222	0.35556	0.37778	0.37778
73	0.42222	0.42222	0.46667	0.42222	0.35556	0.37778
74	0.40000	0.42222	0.42222	0.46667	0.42222	0.35556
75	0.35556	0.40000	0.42222	0.42222	0.46667	0.42222
76	0.24444	0.35556	0.40000	0.42222	0.42222	0.46667
77	0.35556	0.24444	0.35556	0.40000	0.42222	0.42222
78	0.24444	0.35556	0.24444	0.35556	0.40000	0.42222
79	0.22222	0.24444	0.35556	0.24444	0.35556	0.40000
80	0.20000	0.22222	0.24444	0.35556	0.24444	0.35556
81	0.24444	0.20000	0.22222	0.24444	0.35556	0.24444
82	0.17778	0.24444	0.20000	0.22222	0.24444	0.35556
83	0.15556	0.17778	0.24444	0.20000	0.22222	0.24444
84	0.08889	0.15556	0.17778	0.24444	0.20000	0.22222
85	-0.15556	0.08889	0.15556	0.17778	0.24444	0.20000
86	-0.02222	-0.15556	0.08889	0.15556	0.17778	0.24444
87	0.00000	-0.02222	-0.15556	0.08889	0.15556	0.17778
88	0.04444	0.00000	-0.02222	-0.15556	0.08889	0.15556
89	0.28889	0.04444	0.00000	-0.02222	-0.15556	0.08889
90	0.40000	0.28889	0.04444	0.00000	-0.02222	-0.15556
91	0.42222	0.40000	0.28889	0.04444	0.00000	-0.02222
92	0.11111	0.42222	0.40000	0.28889	0.04444	0.00000
93	0.26667	0.11111	0.42222	0.40000	0.28889	0.04444
94	0.26667	0.26667	0.11111	0.42222	0.40000	0.28889
95	0.37778	0.26667	0.26667	0.11111	0.42222	0.40000
96	0.37778	0.37778	0.26667	0.26667	0.11111	0.42222
97	0.37778	0.37778	0.37778	0.26667	0.26667	0.11111
98	0.37778	0.37778	0.37778	0.37778	0.26667	0.26667
99	0.37778	0.37778	0.37778	0.37778	0.37778	0.26667
100	0.37778	0.37778	0.37778	0.37778	0.37778	0.37778
101	0.53333	0.37778	0.37778	0.37778	0.37778	0.37778
102	0.55556	0.53333	0.37778	0.37778	0.37778	0.37778
103	0.55556	0.55556	0.53333	0.37778	0.37778	0.37778
104	0.51111	0.55556	0.55556	0.53333	0.37778	0.37778
105	0.51111	0.51111	0.55556	0.55556	0.53333	0.37778
106	0.48889	0.51111	0.51111	0.55556	0.55556	0.53333
107	0.53333	0.48889	0.51111	0.51111	0.55556	0.55556
108	0.64444	0.53333	0.48889	0.51111	0.51111	0.55556

Data	Y	X₁	X₂	X₃	X₄	X₅
109	0.62222	0.64444	0.53333	0.48889	0.51111	0.51111
110	0.64444	0.62222	0.64444	0.53333	0.48889	0.51111
111	0.64444	0.64444	0.62222	0.64444	0.53333	0.48889
112	0.62222	0.64444	0.64444	0.62222	0.64444	0.53333
113	0.62222	0.62222	0.64444	0.64444	0.62222	0.64444
114	0.66667	0.62222	0.62222	0.64444	0.64444	0.62222
115	0.68889	0.66667	0.62222	0.62222	0.64444	0.64444
116	0.66667	0.68889	0.66667	0.62222	0.62222	0.64444
117	0.68889	0.66667	0.68889	0.66667	0.62222	0.62222
118	0.68889	0.68889	0.66667	0.68889	0.66667	0.62222
119	0.68889	0.68889	0.68889	0.66667	0.68889	0.66667
120	0.51111	0.68889	0.68889	0.68889	0.66667	0.68889
121	0.55556	0.51111	0.68889	0.68889	0.68889	0.66667
122	0.57778	0.55556	0.51111	0.68889	0.68889	0.68889
123	0.62222	0.57778	0.55556	0.51111	0.68889	0.68889
124	0.66667	0.62222	0.57778	0.55556	0.51111	0.68889
125	0.73333	0.66667	0.62222	0.57778	0.55556	0.51111
126	0.80000	0.73333	0.66667	0.62222	0.57778	0.55556
127	0.73333	0.80000	0.73333	0.66667	0.62222	0.57778
128	0.64444	0.73333	0.80000	0.73333	0.66667	0.62222
129	0.53333	0.64444	0.73333	0.80000	0.73333	0.66667
130	0.55556	0.53333	0.64444	0.73333	0.80000	0.73333
131	0.46667	0.55556	0.53333	0.64444	0.73333	0.80000
132	0.40000	0.46667	0.55556	0.53333	0.64444	0.73333
133	0.40000	0.40000	0.46667	0.55556	0.53333	0.64444
134	0.48889	0.40000	0.40000	0.46667	0.55556	0.53333
135	0.44444	0.48889	0.40000	0.40000	0.46667	0.55556
136	0.48889	0.44444	0.48889	0.40000	0.40000	0.46667
137	0.62222	0.48889	0.44444	0.48889	0.40000	0.40000
138	0.64444	0.62222	0.48889	0.44444	0.48889	0.40000
139	0.46667	0.64444	0.62222	0.48889	0.44444	0.48889
140	0.37778	0.46667	0.64444	0.62222	0.48889	0.44444
141	0.15556	0.37778	0.46667	0.64444	0.62222	0.48889
142	0.00000	0.15556	0.37778	0.46667	0.64444	0.62222
143	0.08889	0.00000	0.15556	0.37778	0.46667	0.64444
144	0.22222	0.08889	0.00000	0.15556	0.37778	0.46667
145	0.17778	0.22222	0.08889	0.00000	0.15556	0.37778

Data	Y	X₁	X₂	X₃	X₄	X₅
146	0.13333	0.17778	0.22222	0.08889	0.00000	0.15556
147	0.08889	0.13333	0.17778	0.22222	0.08889	0.00000
148	0.22222	0.08889	0.13333	0.17778	0.22222	0.08889
149	0.13333	0.22222	0.08889	0.13333	0.17778	0.22222
150	0.11111	0.13333	0.22222	0.08889	0.13333	0.17778
151	0.08889	0.11111	0.13333	0.22222	0.08889	0.13333
152	0.11111	0.08889	0.11111	0.13333	0.22222	0.08889
153	-0.02222	0.11111	0.08889	0.11111	0.13333	0.22222
154	-0.02222	-0.02222	0.11111	0.08889	0.11111	0.13333
155	-0.06667	-0.02222	-0.02222	0.11111	0.08889	0.11111
156	-0.17778	-0.06667	-0.02222	-0.02222	0.11111	0.08889
157	-0.20000	-0.17778	-0.06667	-0.02222	-0.02222	0.11111
158	-0.17778	-0.20000	-0.17778	-0.06667	-0.02222	-0.02222
159	-0.15556	-0.17778	-0.20000	-0.17778	-0.06667	-0.02222
160	0.00000	-0.15556	-0.17778	-0.20000	-0.17778	-0.06667
161	-0.06667	0.00000	-0.15556	-0.17778	-0.20000	-0.17778
162	-0.31111	-0.06667	0.00000	-0.15556	-0.17778	-0.20000
163	-0.28889	-0.31111	-0.06667	0.00000	-0.15556	-0.17778
164	-0.24444	-0.28889	-0.31111	-0.06667	0.00000	-0.15556
165	-0.17778	-0.24444	-0.28889	-0.31111	-0.06667	0.00000
166	-0.24444	-0.17778	-0.24444	-0.28889	-0.31111	-0.06667
167	-0.17778	-0.24444	-0.17778	-0.24444	-0.28889	-0.31111
168	-0.08889	-0.17778	-0.24444	-0.17778	-0.24444	-0.28889
169	-0.08889	-0.08889	-0.17778	-0.24444	-0.17778	-0.24444
170	-0.04444	-0.08889	-0.08889	-0.17778	-0.24444	-0.17778
171	-0.22222	-0.04444	-0.08889	-0.08889	-0.17778	-0.24444
172	-0.24444	-0.22222	-0.04444	-0.08889	-0.08889	-0.17778
173	-0.04444	-0.24444	-0.22222	-0.04444	-0.08889	-0.08889
174	-0.13333	-0.04444	-0.24444	-0.22222	-0.04444	-0.08889
175	-0.15556	-0.13333	-0.04444	-0.24444	-0.22222	-0.04444
176	-0.22222	-0.15556	-0.13333	-0.04444	-0.24444	-0.22222
177	-0.26667	-0.22222	-0.15556	-0.13333	-0.04444	-0.24444
178	-0.31111	-0.26667	-0.22222	-0.15556	-0.13333	-0.04444
179	-0.13333	-0.31111	-0.26667	-0.22222	-0.15556	-0.13333
180	-0.24444	-0.13333	-0.31111	-0.26667	-0.22222	-0.15556
181	-0.24444	-0.24444	-0.13333	-0.31111	-0.26667	-0.22222
182	-0.31111	-0.24444	-0.24444	-0.13333	-0.31111	-0.26667

Data	Y	X ₁	X ₂	X ₃	X ₄	X ₅
183	-0.64444	-0.31111	-0.24444	-0.24444	-0.13333	-0.31111
184	-0.75556	-0.64444	-0.31111	-0.24444	-0.24444	-0.13333
185	-0.75556	-0.75556	-0.64444	-0.31111	-0.24444	-0.24444
186	-0.80000	-0.75556	-0.75556	-0.64444	-0.31111	-0.24444
187	-0.66667	-0.80000	-0.75556	-0.75556	-0.64444	-0.31111
188	-0.73333	-0.66667	-0.80000	-0.75556	-0.75556	-0.64444
189	-0.64444	-0.73333	-0.66667	-0.80000	-0.75556	-0.75556
190	-0.62222	-0.64444	-0.73333	-0.66667	-0.80000	-0.75556
191	-0.57778	-0.62222	-0.64444	-0.73333	-0.66667	-0.80000
192	-0.60000	-0.57778	-0.62222	-0.64444	-0.73333	-0.66667
193	-0.55556	-0.60000	-0.57778	-0.62222	-0.64444	-0.73333
194	-0.48889	-0.55556	-0.60000	-0.57778	-0.62222	-0.64444
195	-0.42222	-0.48889	-0.55556	-0.60000	-0.57778	-0.62222
196	-0.40000	-0.42222	-0.48889	-0.55556	-0.60000	-0.57778
197	-0.37778	-0.40000	-0.42222	-0.48889	-0.55556	-0.60000
198	-0.15556	-0.37778	-0.40000	-0.42222	-0.48889	-0.55556
199	-0.02222	-0.15556	-0.37778	-0.40000	-0.42222	-0.48889
200	-0.22222	-0.02222	-0.15556	-0.37778	-0.40000	-0.42222
201	-0.22222	-0.22222	-0.02222	-0.15556	-0.37778	-0.40000
202	-0.13333	-0.22222	-0.22222	-0.02222	-0.15556	-0.37778
203	-0.20000	-0.13333	-0.22222	-0.22222	-0.02222	-0.15556
204	-0.20000	-0.20000	-0.13333	-0.22222	-0.22222	-0.02222
205	-0.24444	-0.20000	-0.20000	-0.13333	-0.22222	-0.22222
206	-0.33333	-0.24444	-0.20000	-0.20000	-0.13333	-0.22222
207	-0.04444	-0.33333	-0.24444	-0.20000	-0.20000	-0.13333
208	-0.24444	-0.04444	-0.33333	-0.24444	-0.20000	-0.20000
209	-0.22222	-0.24444	-0.04444	-0.33333	-0.24444	-0.20000
210	-0.13333	-0.22222	-0.24444	-0.04444	-0.33333	-0.24444
211	-0.17778	-0.13333	-0.22222	-0.24444	-0.04444	-0.33333
212	-0.20000	-0.17778	-0.13333	-0.22222	-0.24444	-0.04444
213	-0.33333	-0.20000	-0.17778	-0.13333	-0.22222	-0.24444
214	-0.33333	-0.33333	-0.20000	-0.17778	-0.13333	-0.22222
215	-0.26667	-0.33333	-0.33333	-0.20000	-0.17778	-0.13333
216	-0.24444	-0.26667	-0.33333	-0.33333	-0.20000	-0.17778
217	-0.08889	-0.24444	-0.26667	-0.33333	-0.33333	-0.20000
218	-0.13333	-0.08889	-0.24444	-0.26667	-0.33333	-0.33333
219	-0.06667	-0.13333	-0.08889	-0.24444	-0.26667	-0.33333

Data	Y	X₁	X₂	X₃	X₄	X₅
220	-0.15556	-0.06667	-0.13333	-0.08889	-0.24444	-0.26667
221	-0.24444	-0.15556	-0.06667	-0.13333	-0.08889	-0.24444
222	-0.28889	-0.24444	-0.15556	-0.06667	-0.13333	-0.08889
223	-0.31111	-0.28889	-0.24444	-0.15556	-0.06667	-0.13333
224	-0.42222	-0.31111	-0.28889	-0.24444	-0.15556	-0.06667
225	-0.24444	-0.42222	-0.31111	-0.28889	-0.24444	-0.15556
226	-0.13333	-0.24444	-0.42222	-0.31111	-0.28889	-0.24444
227	-0.06667	-0.13333	-0.24444	-0.42222	-0.31111	-0.28889
228	-0.15556	-0.06667	-0.13333	-0.24444	-0.42222	-0.31111
229	-0.06667	-0.15556	-0.06667	-0.13333	-0.24444	-0.42222
230	-0.06667	-0.06667	-0.15556	-0.06667	-0.13333	-0.24444
231	0.00000	-0.06667	-0.06667	-0.15556	-0.06667	-0.13333
232	0.11111	0.00000	-0.06667	-0.06667	-0.15556	-0.06667
233	0.08889	0.11111	0.00000	-0.06667	-0.06667	-0.15556
234	0.04444	0.08889	0.11111	0.00000	-0.06667	-0.06667
235	0.11111	0.04444	0.08889	0.11111	0.00000	-0.06667
236	0.08889	0.11111	0.04444	0.08889	0.11111	0.00000
237	0.08889	0.08889	0.11111	0.04444	0.08889	0.11111
238	0.24444	0.08889	0.08889	0.11111	0.04444	0.08889
239	0.31111	0.24444	0.08889	0.08889	0.11111	0.04444
240	0.40000	0.31111	0.24444	0.08889	0.08889	0.11111
241	0.42222	0.40000	0.31111	0.24444	0.08889	0.08889
242	0.48889	0.42222	0.40000	0.31111	0.24444	0.08889
243	0.44444	0.48889	0.42222	0.40000	0.31111	0.24444
244	0.37778	0.44444	0.48889	0.42222	0.40000	0.31111
245	0.44444	0.37778	0.44444	0.48889	0.42222	0.40000
246	0.42222	0.44444	0.37778	0.44444	0.48889	0.42222
247	0.31111	0.42222	0.44444	0.37778	0.44444	0.48889

Lampiran 3 Hasil Training Metode Backpropagation

Data	Node Input					Xtarget
i	X₁	X₂	X₃	X₄	X₅	t_i
1	0,75000	0,80556	0,80556	0,84722	0,84722	0,80556
2	0,80556	0,80556	0,84722	0,84722	0,80556	0,77778
3	0,80556	0,84722	0,84722	0,80556	0,77778	0,62500
4	0,84722	0,84722	0,80556	0,77778	0,62500	0,62500
5	0,84722	0,80556	0,77778	0,62500	0,62500	0,56944
6	0,80556	0,77778	0,62500	0,62500	0,56944	0,45833
7	0,77778	0,62500	0,62500	0,56944	0,45833	0,43056
8	0,62500	0,62500	0,56944	0,45833	0,43056	0,50000
9	0,62500	0,56944	0,45833	0,43056	0,50000	0,61111
10	0,56944	0,45833	0,43056	0,50000	0,61111	0,69444
11	0,45833	0,43056	0,50000	0,61111	0,69444	0,55556
12	0,43056	0,50000	0,61111	0,69444	0,55556	0,55556
13	0,50000	0,61111	0,69444	0,55556	0,55556	0,62500
14	0,61111	0,69444	0,55556	0,55556	0,62500	0,66667
15	0,69444	0,55556	0,55556	0,62500	0,66667	0,68056
16	0,55556	0,55556	0,62500	0,66667	0,68056	0,70833
17	0,55556	0,62500	0,66667	0,68056	0,70833	0,59722
18	0,62500	0,66667	0,68056	0,70833	0,59722	0,50000
19	0,66667	0,68056	0,70833	0,59722	0,50000	0,45833
20	0,68056	0,70833	0,59722	0,50000	0,45833	0,45833
21	0,70833	0,59722	0,50000	0,45833	0,45833	0,51389
22	0,59722	0,50000	0,45833	0,45833	0,51389	0,47222
23	0,50000	0,45833	0,45833	0,51389	0,47222	0,41667
24	0,45833	0,45833	0,51389	0,47222	0,41667	0,54167
25	0,45833	0,51389	0,47222	0,41667	0,54167	0,41667
26	0,51389	0,47222	0,41667	0,54167	0,41667	0,50000
27	0,47222	0,41667	0,54167	0,41667	0,50000	0,51389
28	0,41667	0,54167	0,41667	0,50000	0,51389	0,47222
29	0,54167	0,41667	0,50000	0,51389	0,47222	0,43056
30	0,41667	0,50000	0,51389	0,47222	0,43056	0,45833
31	0,50000	0,51389	0,47222	0,43056	0,45833	0,41667
32	0,51389	0,47222	0,43056	0,45833	0,41667	0,33333
33	0,47222	0,43056	0,45833	0,41667	0,33333	0,40278
34	0,43056	0,45833	0,41667	0,33333	0,40278	0,40278

Data	X ₁	X ₂	X ₃	X ₄	X ₅	t _i
35	0,45833	0,41667	0,33333	0,40278	0,40278	0,30556
36	0,41667	0,33333	0,40278	0,40278	0,30556	0,27778
37	0,33333	0,40278	0,40278	0,30556	0,27778	0,20833
38	0,40278	0,40278	0,30556	0,27778	0,20833	0,19444
39	0,40278	0,30556	0,27778	0,20833	0,19444	0,30556
40	0,30556	0,27778	0,20833	0,19444	0,30556	0,41667
41	0,27778	0,20833	0,19444	0,30556	0,41667	0,41667
42	0,20833	0,19444	0,30556	0,41667	0,41667	0,56944
43	0,19444	0,30556	0,41667	0,41667	0,56944	0,58333
44	0,30556	0,41667	0,41667	0,56944	0,58333	0,62500
45	0,41667	0,41667	0,56944	0,58333	0,62500	0,61111
46	0,41667	0,56944	0,58333	0,62500	0,61111	0,45833
47	0,56944	0,58333	0,62500	0,61111	0,45833	0,52778
48	0,58333	0,62500	0,61111	0,45833	0,52778	0,48611
49	0,62500	0,61111	0,45833	0,52778	0,48611	0,56944
50	0,61111	0,45833	0,52778	0,48611	0,56944	0,62500
51	0,45833	0,52778	0,48611	0,56944	0,62500	0,63889
52	0,52778	0,48611	0,56944	0,62500	0,63889	0,59722
53	0,48611	0,56944	0,62500	0,63889	0,59722	0,59722
54	0,56944	0,62500	0,63889	0,59722	0,59722	0,73611
55	0,62500	0,63889	0,59722	0,59722	0,73611	0,66667
56	0,63889	0,59722	0,59722	0,73611	0,66667	0,63889
57	0,59722	0,59722	0,73611	0,66667	0,63889	0,73611
58	0,59722	0,73611	0,66667	0,63889	0,73611	0,66667
59	0,73611	0,66667	0,63889	0,73611	0,66667	0,58333
60	0,66667	0,63889	0,73611	0,66667	0,58333	0,54167
61	0,63889	0,73611	0,66667	0,58333	0,54167	0,55556
62	0,73611	0,66667	0,58333	0,54167	0,55556	0,70833
63	0,66667	0,58333	0,54167	0,55556	0,70833	0,70833
64	0,58333	0,54167	0,55556	0,70833	0,70833	0,80556
65	0,54167	0,55556	0,70833	0,70833	0,80556	0,80556
66	0,55556	0,70833	0,70833	0,80556	0,80556	0,77778
67	0,70833	0,70833	0,80556	0,80556	0,77778	0,73611
68	0,70833	0,80556	0,80556	0,77778	0,73611	0,73611
69	0,80556	0,80556	0,77778	0,73611	0,73611	0,72222
70	0,80556	0,77778	0,73611	0,73611	0,72222	0,76389
71	0,77778	0,73611	0,73611	0,72222	0,76389	0,79167

Data	X ₁	X ₂	X ₃	X ₄	X ₅	t _i
72	0,73611	0,73611	0,72222	0,76389	0,79167	0,76389
73	0,73611	0,72222	0,76389	0,79167	0,76389	0,76389
74	0,72222	0,76389	0,79167	0,76389	0,76389	0,75000
75	0,76389	0,79167	0,76389	0,76389	0,75000	0,72222
76	0,79167	0,76389	0,76389	0,75000	0,72222	0,65278
77	0,76389	0,76389	0,75000	0,72222	0,65278	0,72222
78	0,76389	0,75000	0,72222	0,65278	0,72222	0,65278
79	0,75000	0,72222	0,65278	0,72222	0,65278	0,63889
80	0,72222	0,65278	0,72222	0,65278	0,63889	0,62500
81	0,65278	0,72222	0,65278	0,63889	0,62500	0,65278
82	0,72222	0,65278	0,63889	0,62500	0,65278	0,61111
83	0,65278	0,63889	0,62500	0,65278	0,61111	0,59722
84	0,63889	0,62500	0,65278	0,61111	0,59722	0,55556
85	0,62500	0,65278	0,61111	0,59722	0,55556	0,40278
86	0,65278	0,61111	0,59722	0,55556	0,40278	0,48611
87	0,61111	0,59722	0,55556	0,40278	0,48611	0,50000
88	0,59722	0,55556	0,40278	0,48611	0,50000	0,52778
89	0,55556	0,40278	0,48611	0,50000	0,52778	0,68056
90	0,40278	0,48611	0,50000	0,52778	0,68056	0,75000
91	0,48611	0,50000	0,52778	0,68056	0,75000	0,76389
92	0,50000	0,52778	0,68056	0,75000	0,76389	0,56944
93	0,52778	0,68056	0,75000	0,76389	0,56944	0,66667
94	0,68056	0,75000	0,76389	0,56944	0,66667	0,66667
95	0,75000	0,76389	0,56944	0,66667	0,66667	0,73611
96	0,76389	0,56944	0,66667	0,66667	0,73611	0,73611
97	0,56944	0,66667	0,66667	0,73611	0,73611	0,73611
98	0,66667	0,66667	0,73611	0,73611	0,73611	0,73611
99	0,66667	0,73611	0,73611	0,73611	0,73611	0,73611
100	0,73611	0,73611	0,73611	0,73611	0,73611	0,73611
101	0,73611	0,73611	0,73611	0,73611	0,73611	0,83333
102	0,73611	0,73611	0,73611	0,73611	0,83333	0,84722
103	0,73611	0,73611	0,73611	0,83333	0,84722	0,84722
104	0,73611	0,73611	0,83333	0,84722	0,84722	0,81944
105	0,73611	0,83333	0,84722	0,84722	0,81944	0,81944
106	0,83333	0,84722	0,84722	0,81944	0,81944	0,80556
107	0,84722	0,84722	0,81944	0,81944	0,80556	0,83333
108	0,84722	0,81944	0,81944	0,80556	0,83333	0,90278

Data	X ₁	X ₂	X ₃	X ₄	X ₅	t _i
109	0,81944	0,81944	0,80556	0,83333	0,90278	0,88889
110	0,81944	0,80556	0,83333	0,90278	0,88889	0,90278
111	0,80556	0,83333	0,90278	0,88889	0,90278	0,90278
112	0,83333	0,90278	0,88889	0,90278	0,90278	0,88889
113	0,90278	0,88889	0,90278	0,90278	0,88889	0,88889
114	0,88889	0,90278	0,90278	0,88889	0,88889	0,91667
115	0,90278	0,90278	0,88889	0,88889	0,91667	0,93056
116	0,90278	0,88889	0,88889	0,91667	0,93056	0,91667
117	0,88889	0,88889	0,91667	0,93056	0,91667	0,93056
118	0,88889	0,91667	0,93056	0,91667	0,93056	0,93056
119	0,91667	0,93056	0,91667	0,93056	0,93056	0,93056
120	0,93056	0,91667	0,93056	0,93056	0,93056	0,81944
121	0,91667	0,93056	0,93056	0,93056	0,81944	0,84722
122	0,93056	0,93056	0,93056	0,81944	0,84722	0,86111
123	0,93056	0,93056	0,81944	0,84722	0,86111	0,88889
124	0,93056	0,81944	0,84722	0,86111	0,88889	0,91667
125	0,81944	0,84722	0,86111	0,88889	0,91667	0,95833
126	0,84722	0,86111	0,88889	0,91667	0,95833	1,00000
127	0,86111	0,88889	0,91667	0,95833	1,00000	0,95833
128	0,88889	0,91667	0,95833	1,00000	0,95833	0,90278
129	0,91667	0,95833	1,00000	0,95833	0,90278	0,83333
130	0,95833	1,00000	0,95833	0,90278	0,83333	0,84722
131	1,00000	0,95833	0,90278	0,83333	0,84722	0,79167
132	0,95833	0,90278	0,83333	0,84722	0,79167	0,75000
133	0,90278	0,83333	0,84722	0,79167	0,75000	0,75000
134	0,83333	0,84722	0,79167	0,75000	0,75000	0,80556
135	0,84722	0,79167	0,75000	0,75000	0,80556	0,77778
136	0,79167	0,75000	0,75000	0,80556	0,77778	0,80556
137	0,75000	0,75000	0,80556	0,77778	0,80556	0,88889
138	0,75000	0,80556	0,77778	0,80556	0,88889	0,90278
139	0,80556	0,77778	0,80556	0,88889	0,90278	0,79167
140	0,77778	0,80556	0,88889	0,90278	0,79167	0,73611
141	0,80556	0,88889	0,90278	0,79167	0,73611	0,59722
142	0,88889	0,90278	0,79167	0,73611	0,59722	0,50000
143	0,90278	0,79167	0,73611	0,59722	0,50000	0,55556
144	0,79167	0,73611	0,59722	0,50000	0,55556	0,63889
145	0,73611	0,59722	0,50000	0,55556	0,63889	0,61111

Data	X ₁	X ₂	X ₃	X ₄	X ₅	t _i
146	0,59722	0,50000	0,55556	0,63889	0,61111	0,58333
147	0,50000	0,55556	0,63889	0,61111	0,58333	0,55556
148	0,55556	0,63889	0,61111	0,58333	0,55556	0,63889
149	0,63889	0,61111	0,58333	0,55556	0,63889	0,58333
150	0,61111	0,58333	0,55556	0,63889	0,58333	0,56944
151	0,58333	0,55556	0,63889	0,58333	0,56944	0,55556
152	0,55556	0,63889	0,58333	0,56944	0,55556	0,56944
153	0,63889	0,58333	0,56944	0,55556	0,56944	0,48611
154	0,58333	0,56944	0,55556	0,56944	0,48611	0,48611
155	0,56944	0,55556	0,56944	0,48611	0,48611	0,45833
156	0,55556	0,56944	0,48611	0,48611	0,45833	0,38889
157	0,56944	0,48611	0,48611	0,45833	0,38889	0,37500
158	0,48611	0,48611	0,45833	0,38889	0,37500	0,38889
159	0,48611	0,45833	0,38889	0,37500	0,38889	0,40278
160	0,45833	0,38889	0,37500	0,38889	0,40278	0,50000
161	0,38889	0,37500	0,38889	0,40278	0,50000	0,45833
162	0,37500	0,38889	0,40278	0,50000	0,45833	0,30556
163	0,38889	0,40278	0,50000	0,45833	0,30556	0,31944
164	0,40278	0,50000	0,45833	0,30556	0,31944	0,34722
165	0,50000	0,45833	0,30556	0,31944	0,34722	0,38889
166	0,45833	0,30556	0,31944	0,34722	0,38889	0,34722
167	0,30556	0,31944	0,34722	0,38889	0,34722	0,38889
168	0,31944	0,34722	0,38889	0,34722	0,38889	0,44444
169	0,34722	0,38889	0,34722	0,38889	0,44444	0,44444
170	0,38889	0,34722	0,38889	0,44444	0,44444	0,47222
171	0,34722	0,38889	0,44444	0,44444	0,47222	0,36111
172	0,38889	0,44444	0,44444	0,47222	0,36111	0,34722
173	0,44444	0,44444	0,47222	0,36111	0,34722	0,47222
174	0,44444	0,47222	0,36111	0,34722	0,47222	0,41667
175	0,47222	0,36111	0,34722	0,47222	0,41667	0,40278
176	0,36111	0,34722	0,47222	0,41667	0,40278	0,36111
177	0,34722	0,47222	0,41667	0,40278	0,36111	0,33333
178	0,47222	0,41667	0,40278	0,36111	0,33333	0,30556
179	0,41667	0,40278	0,36111	0,33333	0,30556	0,41667
180	0,40278	0,36111	0,33333	0,30556	0,41667	0,34722
181	0,36111	0,33333	0,30556	0,41667	0,34722	0,34722
182	0,33333	0,30556	0,41667	0,34722	0,34722	0,30556

Data	X ₁	X ₂	X ₃	X ₄	X ₅	t _i
183	0,30556	0,41667	0,34722	0,34722	0,30556	0,09722
184	0,41667	0,34722	0,34722	0,30556	0,09722	0,02778
185	0,34722	0,34722	0,30556	0,09722	0,02778	0,02778
186	0,34722	0,30556	0,09722	0,02778	0,02778	0,00000
187	0,30556	0,09722	0,02778	0,02778	0,00000	0,08333
188	0,09722	0,02778	0,02778	0,00000	0,08333	0,04167
189	0,02778	0,02778	0,00000	0,08333	0,04167	0,09722
190	0,02778	0,00000	0,08333	0,04167	0,09722	0,11111
191	0,00000	0,08333	0,04167	0,09722	0,11111	0,13889
192	0,08333	0,04167	0,09722	0,11111	0,13889	0,12500
193	0,04167	0,09722	0,11111	0,13889	0,12500	0,15278
194	0,09722	0,11111	0,13889	0,12500	0,15278	0,19444
195	0,11111	0,13889	0,12500	0,15278	0,19444	0,23611
196	0,13889	0,12500	0,15278	0,19444	0,23611	0,25000
197	0,12500	0,15278	0,19444	0,23611	0,25000	0,26389
198	0,15278	0,19444	0,23611	0,25000	0,26389	0,40278
199	0,19444	0,23611	0,25000	0,26389	0,40278	0,48611
200	0,23611	0,25000	0,26389	0,40278	0,48611	0,36111
201	0,25000	0,26389	0,40278	0,48611	0,36111	0,36111
202	0,26389	0,40278	0,48611	0,36111	0,36111	0,41667
203	0,40278	0,48611	0,36111	0,36111	0,41667	0,37500
204	0,48611	0,36111	0,36111	0,41667	0,37500	0,37500
205	0,36111	0,36111	0,41667	0,37500	0,37500	0,34722
206	0,36111	0,41667	0,37500	0,37500	0,34722	0,29167
207	0,41667	0,37500	0,37500	0,34722	0,29167	0,47222
208	0,37500	0,37500	0,34722	0,29167	0,47222	0,34722
209	0,37500	0,34722	0,29167	0,47222	0,34722	0,36111
210	0,34722	0,29167	0,47222	0,34722	0,36111	0,41667
211	0,29167	0,47222	0,34722	0,36111	0,41667	0,38889
212	0,47222	0,34722	0,36111	0,41667	0,38889	0,37500
213	0,34722	0,36111	0,41667	0,38889	0,37500	0,29167
214	0,36111	0,41667	0,38889	0,37500	0,29167	0,29167
215	0,41667	0,38889	0,37500	0,29167	0,29167	0,33333
216	0,38889	0,37500	0,29167	0,29167	0,33333	0,34722
217	0,37500	0,29167	0,29167	0,33333	0,34722	0,44444
218	0,29167	0,29167	0,33333	0,34722	0,44444	0,41667
219	0,29167	0,33333	0,34722	0,44444	0,41667	0,45833

Data	X ₁	X ₂	X ₃	X ₄	X ₅	t _i
220	0,33333	0,34722	0,44444	0,41667	0,45833	0,40278
221	0,34722	0,44444	0,41667	0,45833	0,40278	0,34722
222	0,44444	0,41667	0,45833	0,40278	0,34722	0,31944
223	0,41667	0,45833	0,40278	0,34722	0,31944	0,30556
224	0,45833	0,40278	0,34722	0,31944	0,30556	0,23611
225	0,40278	0,34722	0,31944	0,30556	0,23611	0,34722
226	0,34722	0,31944	0,30556	0,23611	0,34722	0,41667
227	0,31944	0,30556	0,23611	0,34722	0,41667	0,45833
228	0,30556	0,23611	0,34722	0,41667	0,45833	0,40278
229	0,23611	0,34722	0,41667	0,45833	0,40278	0,45833
230	0,34722	0,41667	0,45833	0,40278	0,45833	0,45833
231	0,41667	0,45833	0,40278	0,45833	0,45833	0,50000
232	0,45833	0,40278	0,45833	0,45833	0,50000	0,56944
233	0,40278	0,45833	0,45833	0,50000	0,56944	0,55556
234	0,45833	0,45833	0,50000	0,56944	0,55556	0,52778
235	0,45833	0,50000	0,56944	0,55556	0,52778	0,56944
236	0,50000	0,56944	0,55556	0,52778	0,56944	0,55556
237	0,56944	0,55556	0,52778	0,56944	0,55556	0,55556
238	0,55556	0,52778	0,56944	0,55556	0,55556	0,65278
239	0,52778	0,56944	0,55556	0,55556	0,65278	0,69444
240	0,56944	0,55556	0,55556	0,65278	0,69444	0,75000
241	0,55556	0,55556	0,65278	0,69444	0,75000	0,76389
242	0,55556	0,65278	0,69444	0,75000	0,76389	0,80556
243	0,65278	0,69444	0,75000	0,76389	0,80556	0,77778
244	0,69444	0,75000	0,76389	0,80556	0,77778	0,73611
245	0,75000	0,76389	0,80556	0,77778	0,73611	0,77778
246	0,76389	0,80556	0,77778	0,73611	0,77778	0,76389
247	0,80556	0,77778	0,73611	0,77778	0,76389	0,69444
248	0,77778	0,73611	0,77778	0,76389	0,69444	0,69444
249	0,73611	0,77778	0,76389	0,69444	0,69444	0,63889
250	0,77778	0,76389	0,69444	0,69444	0,63889	0,75000
251	0,76389	0,69444	0,69444	0,63889	0,75000	0,76389
252	0,69444	0,69444	0,63889	0,75000	0,76389	0,76389

Lampiran 4 Syntax Program R Metode *Extreme Learning Machine*

```
library(forecast)
library(tseries)
library(nnfor)

#Input Data
set.seed(123)
data=read.delim("clipboard")
data
dim(data)

#pemeriksaan data missing
apply(data,2,function(x) sum(is.na(x)))

#membuat plot data time series utnuk data "ts.data"
ts.data=ts(data$PT.Mandiri,frequency=5)
plot(ts.data)

#Pembagian Data
train=ts(ts.data[1:252],frequency=5)
test=ts(ts.data[253:257],frequency=5)

##Proses ELM##
fit<-elm(train,hd=9,type=c("lasso","ridge","step","lm"),
         reps=20, comb=c("median","mean","mode"),lags=NULL,
         difforder=0,outplot= c(TRUE),sel.lag=c(FALSE),
         allow.det.season=c(FALSE), barebone=c(FALSE))
fit #tampilan hasil dan error
#Plot ELM
plot(fit)
frc<-predict(fit)
accuracy(frc)
```

Lampiran 5 Syntax Program R Metode *Backpropagation*

```
library(neuralnet)
set.seed(123)
data=read.delim("clipboard")
data

# Check that no data is missing
apply(data,2,function(x) sum(is.na(x)))

#pembagian model data
train <- data[1:252,]
test <- data[253:257,]

#Normalisasi
maxs <- apply(data, 2, max)
mins <- apply(data, 2, min)
scaled <- as.data.frame(scale(data, center = mins, scale = maxs -
mins))
train_ <- scaled[1:252,]
test_ <- scaled[253:257,]

#Fit Neural network
n<-names(train_) #untuk mengatur nama suatu objek
f <- as.formula(paste("Xtarget ~", paste(n[!n %in% "Xtarget"],
collapse = " + ")))
nn <- neuralnet(f,data=train_,hidden=c(9),linear.output=T)

pr.nn <- compute(nn,test_[,1:5])
pr.nn2 <- compute(nn,train_[,1:5])

#hasil prediksi
pr.nn_ <- pr.nn$net.result*(max(data$Xtarget) -
min(data$Xtarget))+min(data$Xtarget)
```

```
pr.nn_2 <- pr.nn2$net.result*(max(data$Xtarget) -  
min(data$Xtarget)) + min(data$Xtarget)  
  
test.r <- (test_$Xtarget)*(max(data$Xtarget) -  
min(data$Xtarget)) + min(data$Xtarget)  
  
train.r <- (train_$Xtarget)*(max(data$Xtarget) -  
min(data$Xtarget)) + min(data$Xtarget)  
  
#Nilai MSE dan MAPE  
MSE.nn <- sum((test.r - pr.nn_)^2)/nrow(test_)  
MSE.nn2 <- sum((train.r - pr.nn_2)^2)/nrow(train_)  
  
MAPE.nn <- sum((abs(test.r - pr.nn_)/(pr.nn_))/nrow(test_)*100)  
MAPE.nn2 <- sum((abs(train.r - pr.nn_2)/(pr.nn_2))/nrow(train_)*100)
```

