

**Perbandingan Metode *Extreme Learning Machine* dan
Multilayer Perceptron Dalam Peramalan Saham Nippon
Paint**

(Studi Kasus : Harga Penutupan Saham Bulanan Nippon Paint dari Tahun 2016 -
2021)

TUGAS AKHIR

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



Disusun Oleh:

Maulidya Ayu Putri

17611007

**PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2021**

**HALAMAN PERSETUJUAN PEMBIMBING
TUGAS AKHIR**

Judul : Perbandingan Metode *Extreme Learning Machine* dan *Multilayer Perceptron* Dalam Peramalan Saham Nippon Paint. (Studi Kasus : Harga Penutupan Saham Bulanan Nippon Paint dari Tahun 2016 - 2021)

Nama Mahasiswa : Maulidya Ayu Putri

NIM : 17611007

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

Yogyakarta, 04 Desember 2021


Mengetahui,

Menyetujui,

Ketua Prodi Statistika

Pembimbing


Dr. Edy Widodo, M.Si.


Rahmadi Yotenka, S.Si., M.Sc.

HALAMAN PENGESAHAN
TUGAS AKHIR

Perbandingan Metode *Extreme Learning Machine* dan *Multilayer Perceptron*
Dalam Peramalan Saham Nippon Paint

(Studi Kasus : Harga Penutupan Saham Bulanan Nippon Paint dari Tahun 2016 -
2021)

Nama Mahasiswa : Maulidya Ayu Putri

NIM : 17611007

TUGAS AKHIR INI TELAH DIUJIKAN

PADA TANGGAL : 8 Desember 2021

Nama Penguji

Tanda Tangan

1. Prof. Drs. Subanar, Ph.D.

.....


2. Tuti Purwaningsih, S.Stat., M.Si.

.....


3. Rahmadi Yotenka, S.Si., M.Sc.

.....



Mengetahui,

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



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

KATA PENGANTAR



Assalamu'alaikum Wr.Wb

Alhamdulillah Robbil 'Alamin, segala puji dan syukur penulis panjatkan kepada Allah SWT karena atas berkah dan rahmat-Nya penulis dapat diberikan kekuatan serta kelancaran sehingga dapat menyelesaikan Laporan Tugas Akhir ini dengan baik. Shalawat serta salam tak lupa juga selalu tercurah kepada junjungan kita yakni Nabi Muhammad SAW beserta keluarga, sahabat dan para pengikutnya hingga akhir zaman.

Tugas akhir ini disusun sebagai hasil proses pembelajaran yang telah penulis dapatkan selama melakukan proses pembelajaran di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia. Tugas akhir ini berjudul “Perbandingan Metode *Extreme Learning Machine* dan *Multilayer Percepton* Dalam Peramalan Saham Nippon Paint” yang ditujukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Program Studi Statistika di Universitas Islam Indonesia.

Dalam kesempatan ini, penulis mengucapkan terima kasih kepada pihak-pihak yang telah memberikan dukungan dan bimbingannya. Ucapan terima kasih ini ditujukan kepada:

1. Bapak Riyanto, Prof., S.Pd., M.Si., Ph.D., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia.
2. Bapak Dr. Edy Widodo, M.Si selaku Ketua Program Studi S1 Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.
3. Bapak Abdullah Ahmad Dzikrullah, S.Si., M.Sc selaku dosen pembimbing akademik yang selalu memberikan nasihat dan arahan dalam bidang akademik kepada penulis selama menjalankan studi di Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.

4. Bapak Rahmadi Yotenka, S.Si., M.Sc. selaku dosen pembimbing tugas akhir yang tentunya telah memberikan bimbingan, arahan, dan motivasi kepada penulis selama penyusunan Laporan Tugas Akhir ini.
5. Seluruh Bapak/Ibu dosen Program Studi Statistika Universitas Islam Indonesia yang telah memberikan ilmu pengetahuan yang bermanfaat dan berguna bagi penulis.
6. Kedua orang tua, adik, dan keluarga besar yang senantiasa mendoakan dan mendukung dalam penulisan Tugas Akhir ini.
7. Keluarga Statistika 2017 yang selalu memberikan semangat dan dukungan dalam memulai dan mengakhiri Laporan Tugas Akhir ini.
8. Seluruh teman-teman seperjuangan, terutama untuk Annisa Shofura, Nisa Ummaroh Fajarani Sasmita, Viola Baby Cortina, Yella Jeneka, Alda Putri Zerlina, dan Faridah Wahyuni yang telah senantiasa saling membantu dalam penulisan Laporan Tugas Akhir ini.

Penulis menyadari bahwa Laporan Tugas Akhir ini masih jauh dari kata sempurna, oleh karena itu diharapkan adanya kritik dan saran yang bersifat mendukung penulis untuk berkembang kedepannya. Diharapkan penulisan Laporan Tugas Akhir ini dapat bermanfaat bagi penulis maupun pembaca yang membutuhkan. Akhir kata, semoga Allah SWT selalu melimpahkan rahmat serta hidayah-Nya kepada kita semua.

Wassalammu'alaikum Wr. Wb

Yogyakarta, 8 Desember 2021

Maulidya Ayu Putri

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PERSETUJUAN PEMBIMBING TUGAS AKHIR.....	ii
HALAMAN PENGESAHAN TUGAS AKHIR	iii
KATA PENGANTAR.....	iv
DAFTAR ISI	vi
DAFTAR TABEL	viii
DAFTAR GAMBAR.....	ix
DAFTAR LAMPIRAN	x
PERNYATAAN	Error! Bookmark not defined.
INTISARI.....	xii
ABSTRACT	xiii
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah	4
1.3. Batasan Masalah.....	4
1.4. Jenis Penelitian dan Metode Analisis.....	5
1.5. Tujuan Penelitian	5
1.6. Manfaat Penelitian	5
BAB II TINJAUAN PUSTAKA.....	6
2.1. Tinjauan Pustaka	6
BAB III LANDASAN TEORI.....	15
3.1. Pengertian Investasi	15
3.2. Pengertian Saham.....	16
3.3. Statistika Deskriptif.....	17
3.4. Pengertian Peramalan.....	18
3.5. Analisis Runtun Waktu	18
3.6. Jaringan Syaraf Tiruan	20
3.6.1 Komponen Jaringan Syaraf Tiruan.....	21
3.6.2 Arsitektur Jaringan Jaringan Syaraf Tiruan.....	22
3.6.3 Fungsi Aktivasi.....	23
3.7. Extreme <i>Learning Machine</i>	24
3.7.1 Proses Normalisasi Data.....	24
3.7.2 Proses <i>Training</i>	25
3.7.3 Proses <i>Testing</i>	26
3.7.4 Proses Denormalisasi Data	26
3.7.5 Arsitektur Jaringan ELM.....	27
3.8. <i>Multilayer Perceptron</i>	27
3.8.1 Arsitektur Jaringan MLP	27
3.8.2 Algoritma <i>Backpropagation</i>	28
3.9. Ukuran Kesalahan Peramalan / Uji Validitas.....	32
BAB IV METODOLOGI PENELITIAN	34
4.1. Populasi Penelitian	34
4.2. Variabel Penelitian	34
4.3. Jenis dan Sumber Data	34

4.4.	Metode Analisis Data	34
4.5.	Diagram Alir Penelitian	35
4.5.1	Diagram Alir Metode <i>Extreme Learning Machine</i>	36
4.5.2	Diagram Alir Metode <i>Multilayer Perceptron</i>	37
	BAB V HASIL DAN PEMBAHASAN.....	39
5.1.	Analisis Deskriptif	39
5.2.	<i>Extreme Learning Machine</i>	40
5.2.1	Pembagian Data <i>Training</i> dan <i>Testing</i>	40
5.2.2	Arsitektur Jaringan <i>Extreme Learning Machine</i>	41
5.2.3	Hasil Peramalan ELM	42
5.2.4	Perhitungan Nilai Akurasi	43
5.3.	Metode <i>Multilayer Perceptron</i>	44
5.3.1	Pembagian Data <i>Training</i> dan <i>Testing</i>	44
5.3.2	Arsitektur Jaringan <i>Multilayer Perceptron</i>	45
5.3.3	Hasil Peramalan MLP.....	46
5.3.4	Perhitungan.....	47
5.4.	Perbandingan Metode Terbaik	48
	BAB VI PENUTUP	49
6.1.	Kesimpulan	49
6.2.	Saran.....	50
	DAFTAR PUSTAKA.....	51
	LAMPIRAN	56

DAFTAR TABEL

Tabel 2.1 Tabel Penelitian Sebelumnya	8
Tabel 2.2 Tabel Perbandingan Variabel	11
Tabel 2.3 Tabel Perbandingan Metode	13
Tabel 3.1 Interpretasi Nilai MAPE	33
Tabel 5.1 Pembagian Persentase Data <i>Training</i> dan <i>Testing</i>	40
Tabel 5.2 Pembagian Data <i>Training</i> dan <i>Testing</i>	40
Tabel 5.3 Pola <i>Input</i> Data <i>Training</i>	40
Tabel 5.4 Tabel Hasil Peramalan	42
Tabel 5.5 Tabel Hasil Nilai Akurasi	43
Tabel 5.6 Pembagian Persentase Data <i>Training</i> dan <i>Testing</i>	44
Tabel 5.7 Pembagian Data <i>Training</i> dan <i>Testing</i>	44
Tabel 5.8 Pola <i>Input</i> Data <i>Training</i>	44
Tabel 5.9 Tabel Hasil Peramalan	46
Tabel 5.10 Tabel Hasil Nilai Akurasi	47
Tabel 5.11 Tabel Hasil Perbandingan Akurasi	48

DAFTAR GAMBAR

Gambar 1.1 <i>Chart Close Price</i> Nippon Paint tahun 2020 – 2021	3
Gambar 3.1 Contoh Pola Siklus (Makridakis S. W., 1999)	19
Gambar 3.2 Contoh Pola Musiman (Makridakis S. W., 1999)	19
Gambar 3.3 Contoh Pola Horizontal (Makridakis S. W., 1999)	19
Gambar 3.4 Contoh Pola Tren (Makridakis S. W., 1999).....	20
Gambar 3.5 Contoh jaringan <i>single layer</i>	22
Gambar 3.6 Contoh jaringan <i>multi layer</i>	22
Gambar 3.7 Contoh jaringan <i>reccurent</i>	23
Gambar 3.8 Fungsi aktivasi sigmoid biner.....	24
Gambar 3.9 Contoh Struktur Jaringan ELM (Ayustina Giusti, 2018)	27
Gambar 3.10 Contoh Jaringan <i>Multilayer Perceptron</i>	28
Gambar 4.1 Diagram Alir Metode TES dan ELM	35
Gambar 4.2 Diagram Alir Metode <i>Extreme Learning Machine</i>	36
Gambar 4.3 Diagram Alir Metode <i>Multilayer Perceptron</i>	37
Gambar 5.1 Grafik Data Aktual Harga Penutupan Saham Harian Nippon Paint	39
Gambar 5.2 Hasil Arsitektur Jaringan <i>Close Price</i>	41
Gambar 5.3 Grafik Hasil Peramalan	43
Gambar 5.4 Hasil Arsitektur Jaringan MLP	45
Gambar 5.5 Grafik Hasil Peramalan	47

DAFTAR LAMPIRAN

Lampiran 1	56
Lampiran 2	57
Lampiran 3	58
Lampiran 4	59
Lampiran 5	61

PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya 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 orang lain, kecuali yang diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

Yogyakarta, 8 Desember 2021



Maulidya Ayu Putri

INTISARI

Perbandingan Metode *Multilayer Perceptron* dan *Extreme Learning Machine* dalam Peramalan Saham Nippon Paint

(Studi Kasus : Harga Penutupan Saham Bulanan Nippon Paint dari Tahun 2016 - 2021)

Maulidya Ayu Putri

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Islam Indonesia

Kegiatan investasi merupakan salah satu pilihan alternatif dalam mendapatkan keuntungan dengan cara yang cukup efektif, saham (*stock*) merupakan salah satu jenis investasi yang paling sering ditawarkan oleh perusahaan dan yang paling banyak diminati oleh para investor. Saham sendiri mempunyai daya tarik yang mampu memberikan keuntungan yang tinggi dengan tingkat risiko tertentu. Saham adalah tanda penyertaan modal seseorang atau pihak (badan usaha) dalam suatu perusahaan yang berbentuk Perseroan Terbatas (PT). Banyak pilihan investasi saham yang bisa dipilih salah satunya adalah saham milik perusahaan manufaktur produk cat Jepang, dapat dilihat dari data historis harga saham Nippon Paint memang menjanjikan untuk berinvestasi. Maka dari itu penelitian ini melakukan peramalan nilai harga penutupan saham Nippon Paint dengan menggunakan data periode Januari 2016 - Oktober 2021 menggunakan metode *Multilayer Perceptron* (MLP) dan *Extreme Learning Machine* (ELM). Yang dimana diantara kedua metode tersebut akan dipilih metode terbaik berdasarkan nilai MAPE yang terkecil. Penelitian ini menggunakan variabel *closing price* saham bulanan Nippon Paint dengan total data 70 bulan. Dari hasil penelitian ini ialah diperoleh nilai akurasi hasil peramalan terkecil dengan metode *Multilayer Perceptron* dengan nilai MAPE sebesar 4,46% yang menunjukkan bahwa metode *Multilayer Perceptron* (MLP) lebih baik digunakan dalam peramalan nilai harga penutupan saham Nippon Paint.

Kata Kunci : Peramalan, Saham, Nippon Paint, *Extreme Learning Machine*, *Multilayer Perceptron*.

ABSTRACT

***Comparison of Multilayer Perceptron and Extreme Learning Machine Methods
in Nippon Paint Stock Forecasting
(Case Study : Nippon Paint Monthly Closing Stock Price from 2016 - 2021)***

Maulidya Ayu Putri

Department of Statistics, Faculty of Mathematics and Natural Sciences
Universitas Islam Indonesia

Investment activities are one of the alternative options in getting profits in a fairly effective way, stocks are one of the types of investment that are most often offered by companies and are most in demand by investors. Stocks themselves have the appeal of being able to provide high profits with a certain level of risk. Shares are a sign of the capital participation of a person or party (business entity) in a company in the form of a Limited Liability Company. There are many stock investment options to choose from, one of which is shares belonging to a Japanese paint product manufacturing company, it can be seen from historical data that Nippon Paint's stock price is indeed promising to invest. Therefore, this study forecasts the closing price of Nippon Paint shares using data for the period January 2016 - October 2021 using the Multilayer Perceptron (MLP) and Extreme Learning Machine (ELM) methods. Which between the two methods will choose the best method based on the smallest MAPE value. This study uses the variable closing price of Nippon Paint's monthly shares with a total of 70 months of data. From the results of this study, it is obtained that the smallest accuracy value of forecasting results with the Multilayer Perceptron method with a MAPE value of 4.46% which indicates that the Multilayer Perceptron (MLP) method is better used in forecasting the closing price of Nippon Paint's stock.

Keywords: *Forecasting, Stock, Nippon Paint, Extreme Learning Machine, Multilayer Perceptron.*

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Kegiatan investasi merupakan salah satu pilihan alternatif dalam mendapatkan keuntungan dengan cara yang cukup efektif. Biasanya investasi dilakukan dalam berbagai bentuk, salah satunya investasi di pasar modal. Investasi pasar modal biasanya dilakukan pada jenis instrumen investasi dengan risiko yang cukup tinggi, misalnya pada aset - aset finansial seperti saham, *warrants*, *options*, serta *futures* baik di pasar modal domestik maupun di pasar modal internasional. Alternatif investasi yang menjanjikan pendapatan tinggi dengan risiko yang tinggi adalah investasi dalam bentuk saham (Tyas Auruma S, 2013).

Saham (*stock*) merupakan salah satu jenis investasi yang paling sering ditawarkan oleh perusahaan dan paling banyak diminati oleh para investor. Saham sendiri mampu memberikan keuntungan yang tinggi dengan tingkat risiko tertentu. Saham merupakan tanda penyertaan modal seseorang atau pihak (badan usaha) dalam suatu perusahaan yang berbentuk Perseroan Terbatas (PT). Penyertaan modal tersebut membuat investor memiliki klaim atas pendapatan perusahaan, klaim atas aset perusahaan, memiliki hak suara dalam Rapat Umum Pemegang Saham (RUPS), dan memiliki hak suara yang dapat turut menentukan kebijakan perusahaan serta menerima bagian dari keuntungan yang dibagikan pada pemegang saham (*dividen*) (Ni Putu Lilis Indiani, 2016).

Generasi milenial mulai tertarik dengan dunia investasi, didasari oleh munculnya fenomena *The Harris Poll* tahun 2018, bahwa sebanyak 92% dari *millennial* sudah suka menabung. Bahkan satu per tiga diantaranya sudah melakukan investasi di luar rencana pensiun yang akan disiapkan. 70% dari *millennial* sudah mengetahui cara berinvestasi. *The Indonesia Capital Market Institute* (TICMI) menemukan hal yang lebih mengejutkan lagi, 61,76% dari 168 responden *millennial* telah menerapkan pengelolaan keuangan dengan investasi. Pilihan investasi generasi *millennial* yang paling tinggi adalah 54,41% di pasar modal, dan sisanya di produk perbankan dan sektor riil. Dari 54,41% hal paling banyak pilihan produk investasi *millennial* sebesar (80,88%) jatuh kepada saham,

lalu disusul 16,18% oleh reksa dana, 1,47% oleh obligasi, dan yang terakhir 1,47% untuk produk investasi lainnya (Vania Onasie, 2020). Ada banyak pilihan investasi saham yang bisa dipilih salah satunya adalah saham milik perusahaan manufaktur produk cat Jepang, dapat dilihat dari data historis harga saham Nippon Paint memang menjanjikan untuk berinvestasi.

Berdiri sejak tahun 1881, Nippon Paint adalah perusahaan manufaktur cat pertama dan merupakan pelopor industri cat di Jepang. Saat ini, Nippon Paint merupakan pemimpin pasaran cat di Jepang. Dari Jepang, Nippon Paint mulai melebarkan sayapnya dengan cepat ke negara-negara lainnya. Salah satunya Indonesia, Nippon Paint Indonesia mulai berdiri pada tahun 1969. Seperti yang diketahui saat ini, Nippon Paint identik dengan produknya yang berkualitas tinggi dengan terobosan yang inovatif, hal ini pula yang menjadikannya sebagai merek cat nomor satu di kawasan Asia Pasifik. Nippon Paint bangga menjadi perusahaan cat terkemuka dalam memberikan solusi terdepan untuk memenuhi kebutuhan global yang senantiasa berubah dari waktu ke waktu. Nippon Paint berkomitmen untuk menyediakan produk berkualitas tinggi secara global (Chemicals, 2021). Sebagai produsen cat dengan sejarah terpanjang di Jepang, Nippon Paint baru saja merayakan hari jadinya yang ke-140 pada 14 Maret 2021. Perayaan ke-140 ini tidak akan mungkin terjadi tanpa kesetiaan para pelanggan, mitra, komunitas regional, dan pemegang saham. Berkat hal tersebut dapat mengembangkan perusahaan ini hingga menjadi produsen cat global terbesar di Asia, yang berkantor pusat di Jepang, dengan tenaga kerja hampir 34.000 orang. Kemitraan 60 tahun Nippon Paint dengan Wuthelam Group memungkinkan kami untuk memimpin bisnis usaha di Asia; dilanjutkan dengan Dunn-Edwards pada tahun 2017, serta Betek Boya dan Duluxgroup Australia & New Zealand pada tahun 2019, kami terus melebarkan sayap bisnis kami ke Amerika Serikat dan Eropa. Masaaki Tanaka menambahkan bahwa memasuki tahun ke-141, Nippon Paint bertekad menjadi pemimpin industri, tidak hanya di Asia, tetapi di seluruh dunia. Perusahaan terus berupaya memperdalam hubungan dengan mitra luar negeri, menciptakan sinergi baru, dan mengembangkan proses kolaboratif yang lebih solid (Liputan6, 2021).



Gambar 1.1 *Chart Close Price* Nippon Paint tahun 2020 – 2021
(Sumber: Yahoo Finance)

Data saham Nippon Paint termasuk kedalam data runtun waktu (*time series*) yang dapat diprediksi untuk melihat hasil beberapa periode kedepannya. Data *time series* merupakan serangkaian pengamatan yang terurut berdasarkan waktu dengan jarak yang sama. Jenis data ini sering ditemui dalam keseharian karena data tersebut dikumpulkan melalui waktu interval yaitu harian, mingguan atau bulanan. Salah satu variabel data *time series* adalah *closing price* yang merupakan harga terakhir saham sebelum pasar ditutup. Oleh karena itu, untuk perdagangan atau saham yang berlangsung pada siang hari, ada harga penutupan di akhir sesi. Harga ini disebut harga penutupan. Harga penutupan ini juga menjadi dasar untuk menghitung indeks pasar saham (Tokopedia, 2021). Dari data harga penutupan yang terkumpul dapat dilihat ada suatu pola didalamnya (Anis Mahfud Al’afi, 2020). Berdasarkan pola tersebut dapat digunakan dalam peramalan untuk periode kedepan. Banyak metode yang dapat digunakan dalam analisis peramalan tetapi yang akan dibahas dalam penelitian ini antara lain adalah metode *Artificial Neural Network*.

Khusus untuk penelitian ini yang digunakan adalah metode *Artificial Neural Network* atau Jaringan Syaraf Tiruan (JST). Jaringan syaraf tiruan (JST) merupakan sebuah sistem kecerdasan buatan yang berfungsi sebagai sistem pengolah informasi yang memiliki sifat seperti kecerdasan saraf otak manusia (Hermawan, 2006). Salah satu prosesnya adalah menggunakan SLFNs (*single hidden layer feedforward*) yang dilihat dari nilai error-nya, metode jaringan syaraf tiruan yang menggunakan SLFNs yaitu *Extreme Learning Machine* (ELM). ELM adalah jaringan syaraf tiruan

feedforward dengan single hidden layer yang pertama kali diperkenalkan oleh Huang tahun 2004. Metode pembelajaran ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed*. Kemudian metode lainnya adalah *Multilayer Perceptron* dengan algoritma *backpropagation* yang juga termasuk kedalam salah satu metode Jaringan Syaraf Tiruan (JST). Kelebihan metode *backpropagation* ini memiliki beberapa unit yang ada dalam satu atau lebih *layer* tersembunyi dibandingkan dengan metode *perceptron* yang terdiri dari *layer* tunggal. Kedua metode tersebut diimplementasikan pada peramalan data *time series* masih jarang dilakukan, oleh karena itu penulis akan membandingkan hasil dari peramalan data *time series* menggunakan metode *Extreme Learning Machine* (ELM) dengan metode *Multilayer Perceptron* dengan algoritma *backpropagation* pada penelitian kali ini.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang sudah dipaparkan, permasalahan yang akan dikaji dalam penelitian ini adalah:

1. Bagaimana gambaran umum mengenai nilai harga penutupan saham Nippon Paint pada periode Januari 2016 - Oktober 2021?
2. Bagaimana hasil peramalan nilai harga penutupan saham Nippon Paint menggunakan metode *Extreme Learning Machine* dan *Multilayer Perceptron*?
3. Bagaimana perbandingan hasil peramalan nilai harga penutupan saham Nippon Paint menggunakan metode *Extreme Learning Machine* dan *Multilayer Perceptron*?

1.3. Batasan Masalah

Batasan masalah dalam penelitian ini disusun agar penelitian ini tidak meluas dari permasalahan yang diangkat, maka pada penelitian ini diberikan batasan-batasan sebagai berikut:

1. Data yang digunakan adalah data saham bulanan Nippon Paint pada periode Januari 2016 - Oktober 2021.
2. Variabel yang digunakan dalam penelitian ini adalah variabel *Close* atau variabel harga penutupan saham.

4. Penelitian ini menggunakan metode *Extreme Learning Machine* dan *Multilayer Perceptron*?
3. Data diolah menggunakan *software RStudio* dan *Ms. Excel*.

1.4. Jenis Penelitian dan Metode Analisis

Jenis penelitian ini merupakan penelitian aplikatif dengan menggunakan metode *Extreme Learning Machine* dan *Multilayer Perceptron*. Metode MLP dan ELM digunakan untuk mendapatkan perbandingan hasil peramalan terbaik pada data saham Nippon Paint.

1.5. Tujuan Penelitian

Adapun tujuan penelitian yang ingin dicapai adalah:

1. Untuk mengetahui gambaran umum mengenai nilai harga penutupan saham Nippon Paint pada Januari 2016 - Oktober 2021.
2. Untuk mengetahui hasil peramalan nilai harga penutupan saham Nippon Paint menggunakan metode *Extreme Learning Machine* dan *Multilayer Perceptron*..
3. Untuk mengetahui perbandingan hasil nilai harga penutupan saham Nippon Paint menggunakan metode *Extreme Learning Machine* dan *Multilayer Perceptron*.

1.6. Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah:

1. Memberikan informasi kepada Nippon Paint atau para investor tentang penerapan ilmu statistika dalam perhitungan peramalan menggunakan metode *time series* dan jaringan syaraf tiruan.
2. Menambah pengetahuan bagi penulis dan pembaca tentang metode peramalan *Extreme Learning Machine* dan *Multilayer Perceptron*.
3. Memberikan informasi penting terkait hasil peramalan sehingga para investor dapat melakukan langkah investasi yang tepat demi mengurangi terjadinya kerugian dalam berinvestasi di suatu perusahaan.

BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Pada penelitian ini digunakan beberapa penelitian terdahulu sebagai referensi dan acuan dalam melakukan penulisan dan penelitian. Berikut beberapa penelitian sebelumnya yang berkaitan dengan metode *Extreme Learning Machine* (ELM) dan *Multilayer Perceptron* (MLP), maupun penelitian yang menggunakan analisis perbandingan peramalan, ataupun yang berkaitan dengan peramalan saham.

Penelitian pertama dengan judul “Metode Hibrida ARIMA dan Multilayer Perceptron untuk Peramalan Jangka Pendek Konsumsi Listrik di Jawa Timur” dilakukan oleh (Ardilla, 2016). Data sampel yang digunakan dalam penelitian ini adalah data penggunaan listrik Jawa Timur pada bulan 1 Januari 2014 hingga 31 Maret 2015. Berdasarkan penelitian yang dilakukan diketahui bahwa secara umum metode MLP menghasilkan metode terbaik yang berarti menghasilkan nilai yang lebih akurat dibandingkan dengan metode ARIMA dan hibrida ARIMA & MLP.

Penelitian selanjutnya dengan judul “Peramalan harga saham menggunakan metode *Extreme Learning Machine* (Studi Kasus: Saham Bank Mandiri)” dilakukan oleh (Muhammad Iqbal Pratama, 2018). Data yang digunakan pada penelitian ini adalah data saham harian Bank Mandiri dari tanggal 16 Maret 2012 – 29 Desember 2017. Berdasarkan analisis yang dilakukan didapatkan nilai MAPE terbaik yang dihasilkan dari penelitian ini adalah sebesar 1,012% dengan menggunakan fungsi aktivasi sigmoid, jumlah neuron sebanyak empat buah, data yang digunakan adalah data satu tahun terakhir dan data uji.

Penelitian selanjutnya dengan judul “Prediksi harga Emas menggunakan *Feed Forward Neural Network* dengan Metode *Extreme Learning Machine*” dilakukan oleh (Nisa Afida Izati, 2019). Data yang digunakan pada penelitian ini adalah data harian harga emas dunia dalam mata uang USD/*troy ounce* pada tahun 2014–2018 dengan data keseluruhan sebanyak 1319 data. Berdasarkan perhitungan, diperoleh MAPE sebesar 0,5499 %. Nilai MAPE yang didapatkan kurang dari 10%, maka dapat dikatakan keakuratan hasil peramalan sangat baik.

Penelitian selanjutnya dengan judul “Peramalan Jumlah Tersangka Penyalahgunaan Narkoba Menggunakan Metode Multilayer Perceptron“ dilakukan oleh (Putu Githa Pratiwi, 2019). Data sampel yang digunakan dalam penelitian ini adalah data yang bersumber dari Badan Narkotika Provinsi Bali dan Ditresnarkoba Polda Bali. Data yang diperoleh merupakan data jumlah tersangka penyalahgunaan narkoba di Provinsi Bali pada Tahun 2007–2018. Berdasarkan penelitian yang dilakukan diketahui bahwa Peramalan jumlah tersangka menggunakan delapan arsitektur Metode Multilayer Perceptron yang memiliki hasil yang berbeda pada tiap percobaannya. Pengukuran tingkat akurasi peramalan dilakukan menggunakan MAD, MSE, dan MAPE. Arsitektur Multilayer Perceptron yang paling baik adalah menggunakan *hidden layer* 3,2 dan *learning rate* 0.1, dengan persentase *error* 3.7%.

Penelitian selanjutnya dengan judul “Perbandingan metode *Holt-Winter’s Exponential Smoothing* dan *Extreme Learning Machine*” dilakukan oleh (Azizah, 2020). Data sampel yang digunakan dalam penelitian ini adalah jumlah penumpang kereta api PT Kereta Api Indonesia (Persero) Daop IV Semarang pada Januari 2015 sampai dengan Desember 2019. Berdasarkan penelitian yang dilakukan diketahui bahwa peramalan jumlah penumpang kereta api kelas ekonomi menggunakan metode Holt Winter’s model multiplicative, didapatkan nilai MAPE sebesar 5.95% sedangkan dengan menggunakan metode ELM didapatkan nilai sebesar 5.24%. Sehingga metode ELM yang lebih baik digunakan untuk peramalan pada studi kasus ini.

Penelitian selanjutnya dengan judul “Model Jaringan Syaraf Tiruan dalam Peramalan Kasus Positif Covid-19 di Indonesia“ dilakukan oleh (Wirawan Setialaksana, 2020). Data sampel yang digunakan dalam penelitian ini adalah data total positif Covid-19 Indonesia yang diperoleh di <https://www.worldometers.info/coronavirus/country/indonesia/>. Berdasarkan penelitian yang dilakukan diketahui bahwa MAPE pada MLP juga menunjukkan bahwa MLP memiliki akurasi yang baik dalam prediksi jangka pendek. Nilai MAPE pada MLP selalu berada dibawah 1% dari 10 titik waktu yang digunakan untuk menguji model.

Tabel 2.1 Tabel Penelitian Sebelumnya

Tahun	Nama Peneliti	Judul	Variabel Penelitian	Hasil Penelitian
2016	Yunita Ardilla	Metode Hibrida ARIMA dan <i>Multilayer Perceptron</i> untuk Peramalan Jangka Pendek Konsumsi Listrik di Jawa Timur	Data konsumsi listrik Jawa Timur pada bulan 1 Januari 2014 hingga 31 Maret 2015	Berdasarkan penelitian yang dilakukan diketahui bahwa secara umum hasil model terbaik dengan metode MLP. menghasilkan nilai yang lebih akurat dibandingkan dengan metode ARIMA dan hibrida ARIMA & MLP. Bahwa tiga model terbaik dihasilkan oleh metode ARIMA. Dan tiga model terbaik lainnya dihasilkan oleh metode hibrida ARIMA & MLP. Sedangkan untuk kesembilan model sisanya, model terbaiknya dihasilkan oleh metode MLP.
2018	Muhammad Iqbal Pratama, Putra Pandu Adikara, Sigit Adinugroho	Peramalan harga saham menggunakan metode <i>Extreme Learning Machine</i> . (Studi Kasus: Saham Bank Mandiri).	Data Saham Harian Bank Mandiri	Berdasarkan hasil pengujian dan analisis, didapatkan kesimpulan nilai MAPE terbaik yang dihasilkan dari penelitian ini adalah sebesar 1,012% dengan menggunakan fungsi aktivasi

				sigmoid, jumlah dan data uji.
2019	Nisa Afida Izati, Budi Warsito, Tatik Widiharis	Prediksi harga Emas menggunakan <i>Feed Forward Neural Network</i> dengan Metode <i>Extreme Learning Machine</i> .	Data Harga Emas	Berdasarkan perhitungan, diperoleh MAPE sebesar 0,5499 %. Nilai MAPE yang didapatkan kurang dari 10%, maka dapat dikatakan keakuratan hasil peramalan sangat baik.
2019	Putu Githa Pratiwi, I Ketut Gede Darma Putra, Desy Purnami Singgih Putri	Peramalan Jumlah Tersangka Penyalahgunaan Narkoba Menggunakan Metode Multilayer Perceptron	Data Jumlah Tersangka Penyalahgunaan Narkoba di Provinsi Bali pada Tahun 2007-2018	Berdasarkan penelitian yang dilakukan diketahui bahwa Peramalan jumlah tersangka menggunakan 8 arsitektur Metode Multilayer Perceptron memiliki hasil yang berbeda. Arsitektur Multilayer Perceptron yang paling baik adalah menggunakan hidden layer 3,2 dan learning rate 0.1, dengan persentase error 3.7%.
2020	Azizah	Perbandingan metode <i>Holt-Winter's Exponential Smoothing</i> dan <i>Extreme Learning Machine</i> .	Data Jumlah Penumpang Kereta Api	Berdasarkan penelitian yang dilakukan diketahui bahwa peramalan jumlah penumpang kereta api kelas ekonomi menggunakan metode Holt

				<p>Winter's model multiplicative, didapatkan nilai MAPE sebesar 5.95% sedangkan dengan menggunakan metode ELM didapatkan nilai sebesar 5.24%. Sehingga metode ELM yang lebih baik digunakan untuk peramalan pada studi kasus ini.</p>
2020	<p>Wirawan Setialaksana, Dwi Rezky Anandari Sulaiman, Shabrina Syntha Dewi, Chairunnisa Ar Lamasitudju, Nini Rahayu Ashadi, Muhammad Asriadi</p>	<p>Model Jaringan Syaraf Tiruan dalam Peramalan Kasus Positif Covid-19 di Indonesia</p>	<p>Data Total Positif Covid-19 Indonesia</p>	<p>Berdasarkan penelitian yang dilakukan diketahui bahwa MAPE pada MLP juga menunjukkan bahwa MLP memiliki akurasi dalam prediksi jangka pendek/harian. MAPE pada MLP selalu berada dibawah 1% dari 10 titik waktu yang digunakan untuk menguji model.</p>

Tabel 2.2 Tabel Perbandingan Variabel

No.	Variabel Penelitian	Penulis						
		Yunita Ardilla (2016)	Muhammad Iqbal Pratama, dkk (2018)	Nisa Afida Izati, dkk (2019)	Putu Githa Pratiwi, dkk (2019)	Azizah (2020)	Wirawan Setialaksana, dkk (2020)	Maulidya Ayu Putri (2021)
1.	Data konsumsi listrik Jawa Timur	✓						
2.	Data saham harian Bank Mandiri		✓					
3.	Data harian harga emas dunia dalam USD/ <i>troy ounce</i>			✓				
4.	Data Jumlah Tersangka Penyalahgunaan Narkoba				✓			
5.	Data Penumpang Kereta Api PT					✓		

No.	Variabel Penelitian	Penulis						
		Yunita Ardilla (2016)	Muhammad Iqbal Pratama, dkk (2018)	Nisa Afida Izati, dkk (2019)	Putu Githa Pratiwi, dkk (2019)	Azizah (2020)	Wirawan Setialaksana, dkk (2020)	Maulidya Ayu Putri (2021)
	Kereta Api Indonesia (Persero)							
6.	Data Total Positif Covid-19 Indonesia						✓	
7.	Data Saham Bulanan Nippon Paint							✓

Tabel 2.3 Tabel Perbandingan Metode

No.	Metode Penelitian	Penulis						
		Yunita Ardilla (2018)	Muhammad Iqbal Pratama, dkk (2018)	Nisa Afida Izati, dkk (2019)	Putu Githa Pratiwi, dkk (2019)	Azizah (2020)	Wirawan Setialaksana, dkk (2020)	Maulidya Ayu Putri (2021)
1.	<i>Multilayer Perceptron</i>	✓			✓		✓	✓
2.	<i>Extreme Learning Machine</i>		✓	✓		✓		✓

Keterangan : Simbol ✓ menunjukkan variabel dan metode yang digunakan.

Berdasarkan penelitian-penelitian sebelumnya, maka penulis melakukan penelitian tentang “Perbandingan Metode *Extreme Learning* dan *Machine Multilayer Perceptron* Dalam Peramalan Saham Nippon Paint” dengan studi kasus harga penutupan saham bulanan Nippon Paint periode Januari 2016 sampai dengan Oktober 2021.

Adapun yang membedakan dari penelitian sebelumnya yaitu data yang digunakan adalah data harga penutupan saham bulanan Nippon Paint dan metode yang digunakan ada dua metode yaitu metode jaringan syaraf tiruan *Extreme Learning Machine* dan *Machine Multilayer Perceptron*.

BAB III

LANDASAN TEORI

3.1. Pengertian Investasi

Investasi adalah komitmen atas sejumlah dana atau sumber daya lainnya yang dilakukan pada saat ini, dengan tujuan memperoleh sejumlah keuntungan dimasa yang akan datang (Tendelilin, 2001). Investasi juga dapat didefinisikan sebagai penundaan konsumsi sekarang untuk digunakan dalam produksi yang efisien selama periode waktu tertentu. Istilah investasi bisa berkaitan dengan berbagai macam aktivitas. Menginvestasikan dana pada sektor *brook* (tanah, emas, mesin atau bangunan) maupun *resource* finansial (deposito, saham atau obligasi), merupakan aktivitas yang umum dilakukan (Jogiyanto, 2003). Konsep dari investasi adalah menempatkan dana yang ada di masa sekarang dalam kurun waktu tertentu untuk mendapatkan keuntungan di masa depan. Investasi dapat terbagi menjadi 3 aspek, yaitu :

1. Aspek uang yang digunakan dan diharapkan, sehingga perlu digunakan konsep uang untuk menilai kelayakan investasi.
2. Aspek waktu saat ini dan dimasa yang akan datang, sehingga penting digunakan konsep waktu untuk menilai kelayakan investasi.
3. Manfaat investasi, dari aspek ini penting adanya untuk melihat manfaat dari berinvestasi serta biaya yang ditimbulkan dengan menggunakan asas manfaat (*money saving advantage proportion*) (Noor H. F., 2009)

Bila dilihat dari jenisnya, investasi dapat dikelompokkan menjadi dua, yaitu investasi langsung dan investasi tidak langsung. Investasi langsung (*Direct Investment*) merupakan investasi pada aset atau faktor produksi untuk melakukan bisnis. Misalnya investasi perkebunan, perikanan, pabrik, toko dan jenis bisnis lainnya. Pada umumnya, dalam pembicaraan sehari-hari jenis investasi ini dianggap pula investasi dalam aset riil, atau investasi yang jelas wujudnya dan mudah dilihat. Dan juga investasi secara langsung ini menghasilkan imbas berganda (*multiplier impact*) yang berdampak besar bagi

masyarakat luas. Investasi ini akan berdampak ke belakang, berupa *input* bisnis, maupun ke masa depan, dalam bentuk *yield* usaha yang merupakan *input* bagi bisnis lain. Investasi secara tidak langsung (*Indirect Investment*) adalah investasi pada aset finansial, bukan pada aset atau faktor produksi. Contoh dari investasi tidak langsung ini, adalah: deposito, investasi pada surat berharga (sekuritas), misalnya saham dan obligasi, CP (*Commercial Paper*), reksadana dan sebagainya. Investasi pada aset keuangan ini juga bertujuan untuk mendapatkan manfaat di masa depan. Manfaat masa depan dari investasi ini lebih dikenal dengan balas jasa investasi, atau untuk menyederhanakannya diklaim dengan istilah bunga (Noor F. H., 2007)

3.2. Pengertian Saham

Saham adalah sertifikat yang menunjukkan bukti kepemilikan suatu perusahaan, dan pemegang saham memiliki hak klaim atas penghasilan dan aktiva perusahaan. (Modal, 2003). Saham yang memiliki karakteristik gabungan antara obligasi dan saham biasa, hal ini dikarenakan saham bisa menghasilkan pendapatan permanen yang biasanya disebut sebagai bunga obligasi, hal ini juga memungkinkan didapatnya hasil yang tidak sesuai seperti yang diharapkan investor. Saham preferen hampir sama dengan saham biasa, karena dua hal ini sama-sama mewakili kepemilikan ekuitas dan diterbitkan tanpa tanggal jatuh tempo yang tertulis di atas lembaran saham tersebut dan membayar dividen (Umam, 2013).

Harga sebuah saham sangat dipengaruhi oleh hukum permintaan dan penawaran yang berlaku. Harga suatu saham akan cenderung naik jika suatu saham mengalami kelebihan permintaan dan cenderung turun apabila terjadi kelebihan penawaran (Modal, 2003). Menurut Maurice Kendall, harga saham tidak dapat diprediksi atau memiliki pola yang tidak menentu. Pergerakannya mengikuti *random walk*, sehingga pemodal harus puas dengan normal *return* dengan tingkat keuntungan yang diberikan oleh mekanisme pasar. Abnormal *return* hanya mungkin terjadi apabila ada sesuatu yang salah dalam efisiensi pasar, keuntungan abnormal hanya bisa diperoleh dari permainan yang tidak *fair* (Umam, 2013).

Data saham yang digunakan biasanya berbentuk data historis yang memiliki beberapa komponen, diantaranya yaitu, *Open*, *High*, *Low*, *Close*, *Adjusted Close*, dan *Volume*. Harga *open* atau harga pembukaan merupakan harga pertama kali transaksi dilakukan dalam hari itu. Harga *open* ini mencerminkan semua informasi pasar yang ada, yang terjadi atau muncul diantara harga penutupan sehari sebelumnya dan pada saat-saat terakhir pemodal boleh memasukkan *order* ke mesin bursa. Harga *high* (tertinggi) dan harga *low* (terendah) merupakan kisaran harga pergerakan harian dari saham tersebut dimana pemodal memiliki keberanian atau rasionalitas untuk melakukan posisi beli atau posisi jual. *Close* menunjukkan harga penutupan suatu saham dalam satu hari perdagangan. *Adjusted Close Price* yaitu harga saham penutupan yang sudah disesuaikan ketika terjadi aksi korporasi perusahaan, dalam hal ini adalah *dividen* dan *stock split*. *Volume* dapat didefinisikan sebagai jumlah saham atau kontrak pada sebuah saham atau pada semua saham dalam satu bursa yang diperdagangkan dalam periode tertentu. Dengan kata lain, setiap terjadi jual atau beli saham yang dilakukan oleh seseorang maka inilah *volume* (Sari, 2020).

3.3. Statistika Deskriptif

Statistik deskriptif adalah bidang ilmu statistika yang mempelajari cara-cara pengumpulan, penyusunan, dan penyajian data pada suatu penelitian. Statistik deskriptif merupakan bagian dari ilmu statistik yang bertujuan untuk meringkas, menyajikan dan mendeskripsikan data dalam bentuk yang mudah dipahami sehingga dapat memberikan informasi tersebut secara lebih lengkap. Statistik deskriptif hanya berhubungan dengan hal menguraikan atau memberikan keterangan-keterangan mengenai suatu data atau keadaan atau fenomena, dengan kata lain hanya melihat gambaran secara umum dari data yang didapatkan. Penelitian deskriptif merupakan metode penelitian yang digunakan untuk menemukan pengetahuan yang seluas-luasnya terhadap objek penelitian pada suatu masa tertentu. Kumpulan data yang diperoleh pada data statistika deskriptif akan disajikan secara 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 kecenderungan suatu gugus data (Walpole, 1995).

3.4. Pengertian Peramalan

Menurut (Makridakis S. e., 1988), peramalan atau *estimating* merupakan analisis yang dilakukan untuk mendapatkan nilai prediksi sebuah variabel berdasarkan dari nilai yang diketahui dari variabel tersebut atau variabel yang berhubungan. Peramalan juga dapat didasarkan pada keahlian *judgment*, yang pada gilirannya didasarkan pada informasi historis dan pengalaman. Menurut (Buffa, 1996), peramalan atau *estimating* diartikan sebagai penggunaan teknik-teknik statistik dalam bentuk gambaran masa depan berdasarkan pengolahan angka-angka historis. Menurut (Rusdiana, 2014), peramalan adalah salah satu kegiatan yang dianggap mampu dijadikan dasar dalam pembuatan strategi produksi perusahaan. Peramalan bertujuan untuk mendapatkan peramalan yang dapat meminimumkan kesalahan meramal dan dapat diukur dengan *Mean Absolute Percent Error* (MAPE).


3.5. Analisis Runtun Waktu

Analisis runtun waktu pertama kali diperkenalkan dan dikembangkan pada tahun 1970 oleh Box dan Jenkins. Analisis runtun waktu adalah himpunan observasi yang diurutkan dalam waktu tertentu (Soejoeti, 1987). Data runtun waktu yaitu, data yang dikumpulkan dari waktu ke waktu untuk dilihat pengembangannya (misalnya, pengembangan penjualan, produksi, harga, dll.). Dalam deskripsi data tersebut akan menunjukkan fluktuasi dan dapat digunakan untuk dasar dalam menentukan *trend* yang dapat digunakan sebagai dasar untuk *forecast*. yang berguna untuk perencanaan dasar dan menarik kesimpulan (Supranto, 2001).

Saat melakukan analisis deret waktu, beberapa metode digunakan sesuai dengan model data yang akan digunakan. Inilah mengapa itu penting mengetahui jenis model data yang akan digunakan dalam analisis sehingga peneliti dapat menemukan metode yang benar. Berikut adalah beberapa jenis model deret data menurut (Hanke, 2005) :


1. Pola siklus (*cycle*), pola siklus memiliki pola yang berulang antara peristiwa secara berkala tetapi pada interval yang tidak teratur. Pola

siklus terjadi ketika data dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti siklus bisnis.




Gambar 3.1 Contoh Pola Siklus (Makridakis S. W., 1999)

2. Pola musiman (*seasonal*), pola musiman terjadi jika data untuk masing-masing periode memiliki pola yang berulang atau sama pergerakannya. Hal ini ditandai dengan puncak dan lembah yang berulang pada interval yang konsisten.




Gambar 3.2 Contoh Pola Musiman (Makridakis S. W., 1999)

3. Pola horizontal, pola horizontal adalah pola yang terjadi ketika Di antara nilai rata-rata yang konstan ada nilai yang berfluktuasi. Namun, fluktuasi yang dimaksud di sini adalah angka yang naik dan turun tergantung pada kondisi.



Gambar 3.3 Contoh Pola Horizontal (Makridakis S. W., 1999)

4. Pola tren, pola tren adalah pola yang terjadi sebagai akibat dari data yang terus menerus naik turun terus menerus sampai waktu tertentu.



Gambar 3.4 Contoh Pola Tren (Makridakis S. W., 1999)

3.6. Jaringan Syaraf Tiruan

Jaringan syaraf tiruan adalah salah satu sistem proses informasi yang dirancang untuk meniru cara kerja otak manusia untuk memecahkan masalah dengan melakukan proses belajar melalui perubahan bobot sinapsis. Jaringan saraf tiruan mampu melakukan pengenalan kegiatan masa lalu berdasarkan data. Data masa lalu akan dipelajari oleh jaringan syaraf tiruan sampai didapatkan kemampuan untuk membuat keputusan tentang data yang tidak pernah dipelajari sebelumnya. Sejak ditemukan oleh Mc.Culloch dan Pitts, jaringan syaraf tiruan telah berkembang pesat dan juga banyak digunakan pada aplikasi-aplikasi. Jaringan syaraf tiruan merupakan jaringan yang dapat memodelkan fungsi sistem saraf manusia dalam melaksanakan suatu tugas tertentu. Pemodelan ini didasarkan pada kemampuan otak manusia untuk mengatur sel (*neuron*), sehingga memiliki kemampuan untuk melakukan tugas-tugas tertentu, khususnya pengenalan pola dengan efisiensi jaringan lebih tinggi (Suyanto, 2013).

Sebagai sistem yang diketahui dapat menirukan perilaku manusia, biasanya sistem ini mempunyai ciri khas yang mampu menunjukkan kemampuan dalam hal:

1. Menyimpan informasi.
2. Menggunakan informasi yang dimiliki untuk melakukan pekerjaan dan menarik kesimpulan.

3. Beradaptasi dengan keadaan baru.
4. Berkomunikasi dengan penggunanya.

Keuntungan utama dari sistem jaringan syaraf tiruan adalah kemampuan untuk belajar dari contoh yang diberikan dengan menyediakan atau melatih data, sedangkan untuk kelemahan utama jaringan saraf tiruan adalah membutuhkan pelatihan untuk operasi dan memakan waktu untuk prosesnya. Jaringan saraf tiruan jauh lebih sederhana dibandingkan dengan saraf buatan manusia asli, Jaringan syaraf tiruan dipengaruhi oleh 3 hal, yaitu:

1. Pola – pola antara hubungan neuron yang disebut arsitektur jaringan.
2. Penentuan bobot penghubung yang disebut metode *training/learning/* algoritma.
3. Aktivasi yang digunakan.

3.6.1 Komponen Jaringan Syaraf Tiruan

Adanya pengembangan pada komponen jaringan syaraf tiruan yang pada awalnya hanya mempunyai dua lapisan pada komponennya yaitu *input* dan *output* kemudian dikembangkan sehingga bertambah satu lapisan lagi yaitu lapisan *hidden layer* yang terletak diantara *input* dan *output layer* (Hermawan, 2006). Sehingga komponen jaringan syaraf tiruan dapat dibagi menjadi tiga, yaitu:

1. *Input layer*

Pada lapisan ini terdapat neuron yang mempunyai nilai masukannya masing-masing. *Neuron* tergantung dari banyaknya *input* pada suatu pola. *Input* pada lapisan ini menggambarkan suatu masalah.

2. *Hidden layer*

Pada lapisan tersembunyi ini di dalamnya terjadi semua proses fase pelatihan dan fase pengenalan. Biasanya pada jaringan syaraf tiruan hanya terdiri dari satu *hidden layer* saja, namun dapat berubah tergantung dari arsitektur yang akan dirancang. *Hidden layer* merupakan lapisan penghubung antara *input layer* dan *output layer*.


3. *Output layer*

Pada lapisan ini akan menghasilkan keluaran dari perhitungan keseluruhan. Hasil keluaran yang dihasilkan merupakan output JST dari suatu permasalahan.

3.6.2 Arsitektur Jaringan Jaringan Syaraf Tiruan

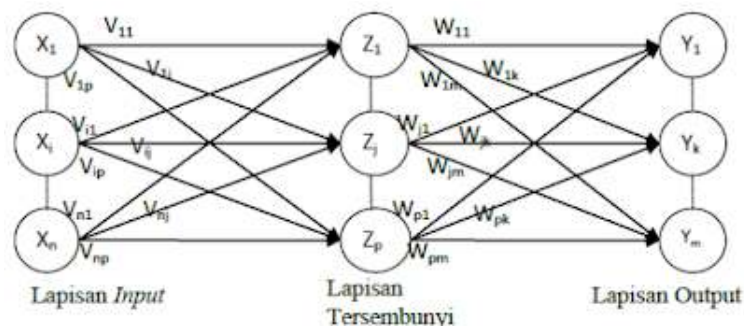
Berdasarkan jumlah lapisan arsitektur jaringan syaraf tiruan dapat diklasifikasikan menjadi tiga kelas yang berbeda itu yaitu:

1. Jaringan lapisan tunggal (*single layer network*) terdiri dari semua unit *input* dari jaringan ini terhubung di semua unit *output*, walaupun dengan bobot yang berbeda.



Gambar 3.5 Contoh jaringan *single layer*


2. Jaringan lapisan jamak (*multi layer*) adalah jaringan lapisan jamak yang merupakan perpanjangan dari jaringan lapisan tunggal, jaringan lapisan jamak ini memperkenalkan lapisan tersembunyi (*hidden layer*) yang memiliki node yang disebut *neuron* tersembunyi (*hidden layer*).



Gambar 3.6 Contoh jaringan *multi layer*

3. Jaringan lapisan *reccurent* hamper sama dengan jaringan lapisan tunggal maupun ganda. Yang membedakan adalah *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.




Gambar 3.7 Contoh jaringan *reccurent*

3.6.3 Fungsi Aktivasi

Fungsi aktivasi adalah fungsi yang menggambarkan hubungan antara tingkat aktivasi internal atau *summation function* yang mungkin berbentuk linier atau nonlinier. Fungsi aktivasi digunakan untuk menentukan *output* dari suatu *neuron*. Dalam penelitian ini, digunakan fungsi aktivasi sigmoid biner karena fungsi sigmoid biner memiliki nilai range 0 sampai 1, mudah diturunkan, *kontinue*, dan merupakan fungsi yang tidak turun. Fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai *output* yang terletak pada interval 0 sampai 1. Namun fungsi ini juga dapat digunakan oleh jaringan syaraf yang nilai ouputnya 0 atau 1 (Ardilla, 2016). Fungsi sigmoid biner dirumuskan sebagai berikut.

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



Gambar 3.8 Fungsi aktivasi sigmoid biner

3.7. Extreme Learning Machine

Extreme Learning Machine (ELM) termasuk dalam *single layer feedforward neural network* (SLFN) dimana nilai bobot input dan kemiringan dihasilkan secara otomatis (Huang, 2012). (Ardilla, 2016) Keuntungan dari ELM adalah waktu pelatihan yang cepat. Tahapan yang ada di ELM meliputi proses normalisasi data, *training*, *testing*, denormalisasi data.

3.7.1 Proses Normalisasi Data

Normalisasi data dilakukan karena range nilai *input* awal yang tidak sama, yaitu bisa saja bernilai puluhan hingga ribuan. *Input* akan diproses ke nilai *output* yang kecil sehingga data yang digunakan harus disesuaikan agar dapat diproses untuk mendapatkan nilai normalisasi yang kecil. Dalam penelitian ini, data yang digunakan akan disesuaikan dengan cara menormalisasi data. Berikut adalah proses normalisasi data menggunakan metode *Min-Max Normalization*:

$$d' = D_{\min b} + \left(\frac{(X_t - D_{\min})(D_{\max b} - D_{\min b})}{D_{\max} - D_{\min}} \right) \quad (3.2)$$

Keterangan:

d' = nilai dari hasil normalisasi data

X_t = nilai data aktual

D_{\min} = nilai minimum pada data aktual

D_{\max} = nilai maksimal pada data actual

$D_{\min b}$ = nilai minimum baru

$D_{\max b}$ = nilai maksimal baru

3.7.2 Proses *Training*

Proses *training* harus dilakukan sebelum melakukan proses prediksi. Proses ini bertujuan untuk mendapatkan nilai *output weight*. Langkah-langkah proses *training* yaitu sebagai berikut:

1. Langkah pertama adalah menginisialisasi *input weight* dan bias. Nilai ini diinisialisasi secara acak dengan range antara -1 hingga 1.
2. Keluaran di *hidden layer* dihitung menggunakan fungsi aktivasi. Langkah pertama adalah menghitung keluaran *hidden layer* (H_{init}), setelah nilai H_{init} didapatkan kemudian dihitung menggunakan fungsi aktivasi sigmoid.

$$H(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$

Berikut adalah persamaan untuk menghitung keluaran di *hidden layer*:

$$H_{init} = X.W \quad (3.4)$$

Keterangan:

H_{init} = Matriks keluaran *hidden layer*.

W = Bobot *input*.

X = *Input* data yang digunakan setelah normalisasi.

3. Menghitung *output weight*. Untuk mendapatkan *output weight*, langkah pertama yang harus dilakukan adalah menstranspose matriks hasil keluaran *hidden layer* dengan fungsi aktivasi. Setelah ditranspose, matriks transpose tersebut dikalikan dengan matriks hasil keluaran *hidden layer* dengan fungsi aktivasi biasa disebut matriks H . Langkah selanjutnya adalah menghitung nilai invers dari matriks H tersebut. Setelah itu menghitung matriks Moore-Penrose Generalized Invers dari hasil keluaran *hidden layer* dengan fungsi aktivasi. Berikut adalah persamaan untuk menghitung nilai *output weight*:

$$\beta = H^+T \quad (3.5)$$

Keterangan:

β = Matriks *Output weight*.

H^+ = Matriks Moore-Penrose Generalized Invers dari matriks H .

T = Matriks Target.

3.7.3 Proses *Testing*

Pada proses ini 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:

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

$$Y = H\beta \quad (3.6)$$

Keterangan:

Y = *Output layer* yang merupakan hasil prediksi.

β = nilai *output weight* didapatkan dari proses *training*.

H = Keluaran di *hidden layer* dihitung dengan fungsi aktivasi.

7. 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:

$$d = d' (D_{\max} - D_{\min}) + D_{\min} \quad (3.7)$$

Keterangan:

d' = nilai hasil prediksi sebelum didenormalisasi

d = nilai asli setelah didenormalisasi

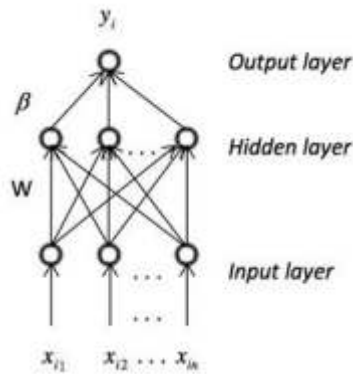
D_{\min} = nilai minimum pada data aktual

D_{\max} = nilai maksimal pada data aktual

(Ayustina Giusti, 2018).

3.7.5 Arsitektur Jaringan ELM

Arsitektur jaringan metode ELM terdiri p unit pada *input layer*, m unit pada satu *hidden layer* (sehingga disebut *single hidden layer*), satu bias, dan satu *output*. Juga terdapat bobot penghubung antara *input nodes* dan *hidden nodes*, antara bias dan *hidden nodes*, serta antara *hidden nodes* dan *output*. Secara umum struktur ELM adalah sebagai berikut:




Gambar 3.9 Contoh Struktur Jaringan ELM (Ayustina Giusti, 2018)

3.8. Multilayer Perceptron

3.8.1 Arsitektur Jaringan MLP

Multilayer perceptron memiliki jaringan dengan banyak lapisan, satu atau lebih lapisan yang terletak diantara lapisan *input* dan lapisan *output*. Lapisan-lapisan ini memiliki bobot yang terletak antara dua lapisan yang bersebelahan. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit daripada lapisan dengan lapisan tunggal, dengan pembelajaran yang lebih rumit (Ardilla, 2016).



Gambar 3.10 Contoh Jaringan *Multilayer Perceptron*

3.8.2 Algoritma *Backpropagation*

Backpropagation diketahui pertama kali diperkenalkan oleh Rumelhart, Hinon, dan Wiliam pada tahun 1986, kemudian dilanjutkan pengembangannya oleh Rumelhart dan McClelland pada tahun 1988. *Backpropagation* merupakan bagian dari jaringan syaraf tiruan yang sering disebut sebagai *supervised learning* (Riska Yanu Fa'rifah, 2017). *Backpropagation* terdiri dari banyak lapisan atau *Multilayer* yang setiap unit *input layer* terhubung dengan setiap unit di *hidden layer*, setiap unit *hidden layer* terhubung dengan masing-masing unit *output layer*.

Dapat dikatakan *backpropagation* karena sistem komputasi yang dijalankan bersifat *feedforward* dan *backforward*, pertama-tama jaringan diberikan pola *input* sebagai pola pelatihan yang menuju ke unit *hidden layer* yang selanjutnya diteruskan ke lapisan *output*. Jika hasil dari lapisan *output* tidak sesuai dengan hasil yang diharapkan maka keluaran yang didapatkan akan menyebar mundur (*backforward*) ke *hidden layer* dan selanjutnya diteruskan ke lapisan *input* kembali. Hal tersebut yang menyebabkan komputasi ini disebut *backpropagation* (Kusumadewi, 2017). *Backpropagation* memiliki 3 langkah utama, yaitu:

1. Data dimasukkan dalam input jaringan (*feedforward*),
2. Dilakukan perhitungan dan juga *backpropagation* dari *error* yang ditemukan,
3. Pembaruan bobot dan bias.

Adapun 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 pemberhentian belum terpenuhi, kerjakan langkah 2 – 9,

Langkah 2 : Untuk setiap pasangan *training*, lakukan langkah 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 di atasnya (*hidden unit*)

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

$$Z_{net_j} = V_{0j} + \sum_{i=1}^n X_i V_{ij} \quad (3.8)$$

Keterangan:

Z_{net_j} = faktor keluaran pada *hidden layer*

V_{0j} = bobot bias pada *hidden layer*

X_i = unit *input*

V_{ij} = bobot unit *input* terhadap unit *hidden layer*

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

$$Z_j = \frac{1}{1 + \exp(-z_{net_j})} \quad (3.9)$$

Keterangan:

Z_j = nilai fungsi aktivasi keluaran pada unit tersembunyi

Z_{net_j} = faktor keluaran pada *hidden layer*

Dilanjutkan dengan 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 sinyalsinyal masuk yang berbobot menggunakan berikut:

$$Y_{net_k} = W_{0k} + \sum_{j=1}^p Z_j W_{jk} \quad (3.10)$$

Keterangan:

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

W_{0k} = Bobot bias pada unit *output*

Z_j = Nilai dari fungsi aktivasi pada unit tersembunyi

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

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

$$Y_k = \frac{1}{1 + \exp(-Y_{net_k})} \quad (3.11)$$

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:

$$\delta_k = (t_k - Y_k) f'(Y_{net_k}) = (t_k - Y_k) Y_k (1 - Y_k) \quad (3.12)$$

Keterangan:

δ_k = Faktor kesalahan pada lapisan *output*

t_k = target yang dicapai

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

Dilanjutkan dengan menghitung koreksi bobot (digunakan untuk memperbaiki W_{jk}) persamaan yang digunakan sebagai berikut:

$$\Delta W_{jk} = \alpha \delta_k Z_j \quad (3.13)$$

Keterangan:

ΔW_{jk} = Suku perubahan bobot

α = konstanta laju pelatihan (*learning rate*)

δ_k = Faktor kesalahan pada lapisan *output*

Z_j = nilai fungsi aktivasi keluaran pada unit tersembunyi

Dihitung juga nilai korelasi bias (digunakan untuk memperbaiki W_0) dengan menggunakan persamaan berikut ini:

$$\Delta W_{0k} = \alpha \delta_k \quad (3.14)$$

Keterangan:

ΔW_{0k} = Suku perubahan bobot bias

α = konstanta laju pelatihan (*learning rate*)

δ_k = Faktor kesalahan pada lapisan *output*

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

$$\delta net_j = \sum_{k=1}^m \delta_k W_{jk} \quad (3.15)$$

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:

$$\delta_j = \delta net_j f' (Z net_j) = \delta net_j Z_j (1 - Z_j) \quad (3.16)$$

Keterangan:

δ_j = Faktor kesalahan pada lapisan tersembunyi

δnet_j = Jumlah kesalahan dari unit tersembunyi

Z_j = nilai fungsi aktivasi keluaran pada unit tersembunyi

Dilanjutkan dengan menghitung koreksi bobot (digunakan untuk memperbaiki V_{ij}) menggunakan persamaan berikut ini :

$$\Delta V_{ij} = \alpha \delta_j X_i \quad (3.17)$$

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*

Dihitung juga koreksi bias (digunakan untuk memperbaiki V_0) menggunakan persamaan berikut ini:

$$\Delta V_{0j} = \alpha \delta_j \quad (3.18)$$

Keterangan:

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

α = konstanta laju pelatihan (*learning rate*)

δ_j = Faktor kesalahan pada lapisan tersembunyi

Pembaruan 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:

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (3.19)$$

Keterangan:

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

ΔW_{jk} = Suku perubahan bobot

Masing-masing 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:

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (3.20)$$

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 kembali langkah 2-9.

3.9. Ukuran Kesalahan Peramalan / Uji Validitas

Biasanya pada suatu peramalan akan ada evaluasi terhadap suatu hasil peramalan, dengan menggunakan ukuran kesalahan peramalan. Hasil prediksi terbaik memiliki nilai kesalahan peramalan terkecil. Ukuran kesalahan yang digunakan dalam penelitian ini termasuk dalam ukuran

statistik standar yaitu nilai rata-rata dari kesalahan persentase absolut (*Mean Absolute Percentage Error*). *Mean Absolute Percentage Error* (MAPE) adalah salah satu metode yang menetapkan kesalahan prediksi hasil data aktual dalam bentuk persentase. Semakin rendah nilai MAPE yang dihasilkan, berarti hasil peramalan mendekati data aktual. Berikut adalah persamaan yang digunakan untuk melakukan perhitungan MAPE :

$$MAPE = \frac{1}{N} \sum_{i=1}^n \frac{|Y - Y_{pred}|}{Y} \quad (3.21)$$

Keterangan :

n = Jumlah data.

Y_t = Nilai prediksi pada periode ke-t.

Berikut tabel kategori dari nilai MAPE menurut (Moreno, Pol, Abad, & B.C., 2013) :

Tabel 3.1 Interpretasi Nilai MAPE

MAPE	Interpretasi
< 10%	Kemampuan peramalan sangat baik
10 – 20%	Kemampuan peramalan baik
20 – 50%	Kemampuan peramalan layak/memadai
>50%	Kemampuan peramalan buruk

BAB IV

METODOLOGI PENELITIAN

Secara umum pada metodologi penelitian meliputi unsur-unsur:

4.1. Populasi Penelitian

Populasi yang digunakan dalam penelitian ini adalah harga saham bulanan *Nippon Paint Holdings Co.* Sampel yang diambil adalah harga penutupan saham harian *Nippon Paint Holdings Co.* periode Januari 2016 sampai dengan Oktober 2021, dengan total data yang digunakan dalam penelitian ini adalah sebanyak 70 data.

4.2. Variabel Penelitian

Variabel yang digunakan dalam penelitian ini adalah harga penutupan saham (*close*) *Nippon Paint Holdings Co.* dari bulan Januari 2016 sampai dengan Oktober 2021. Variabel *close* digunakan karena diketahui bahwa variabel *close* merupakan acuan pada harga pembukaan (*open*).

4.3. Jenis dan Sumber Data

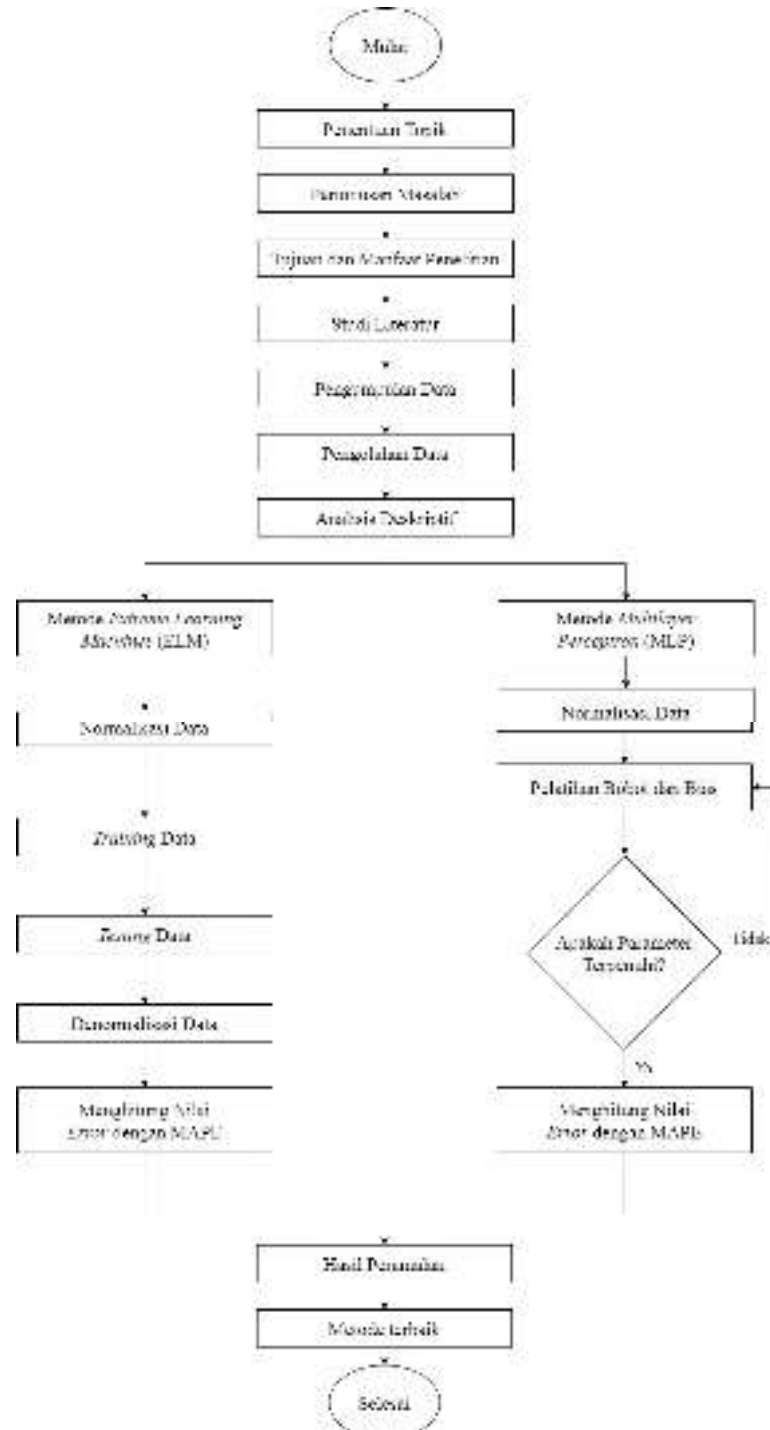
Data yang digunakan dalam penelitian ini adalah data sekunder atau data yang didapatkan dengan cara tidak turun langsung ke lapangan. Data penutupan (*close*) didapatkan dari laman *yahoo finance* yang diakses pada tanggal 26 Oktober 2021.

4.4. Metode Analisis Data

Metode dasar yang digunakan dalam penelitian ini adalah analisis deskriptif sebagai alat untuk mengetahui gambaran data secara umum. Pada metode peramalan terdapat dua metode yang digunakan untuk membandingkan yaitu metode *Extreme Learning Machine* dan *Multilayer Perceptron*. Berdasarkan kedua metode tersebut akan dibandingkan hasil peramalannya dengan menggunakan perbandingan nilai ukuran kesalahan atau nilai MAPE. Penelitian ini dilakukan dengan menggunakan bantuan *software RStudio* dan *Microsoft Excel 2016*.

4.5. Diagram Alir Penelitian


Dalam penelitian ini digunakan dua metode yaitu *Extreme Learning Machine* dan *Multilayer Perceptron*, berikut akan dijelaskan diagram alir dari kedua metode tersebut.



Gambar 4.1 Diagram Alir Metode TES dan ELM

4.5.1 Diagram Alir Metode *Extreme Learning Machine*

Berikut adalah diagram alir untuk metode *Extreme Learning Machine* (ELM):



Gambar 4.2 Diagram Alir Metode *Extreme Learning Machine*

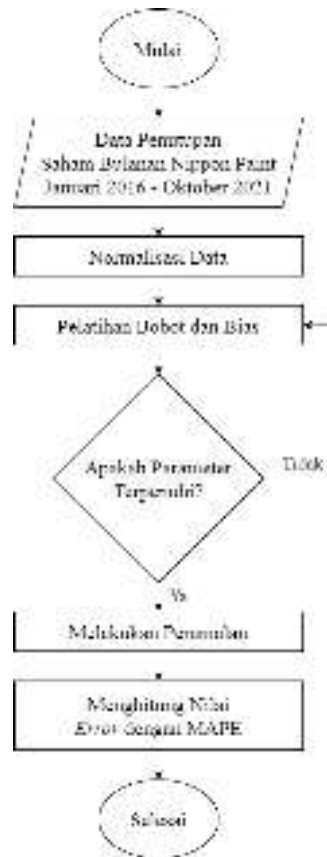
Berikut adalah langkah-langkah dalam melakukan peramalan menggunakan metode *Extreme Learning Machine* (ELM) :

1. *Input* data saham bulanan Nippon Paint periode Januari 2016 sampai dengan Oktober 2021 ke dalam *software* R.
2. Selanjutnya dilakukan proses normalisasi data menggunakan metode *Min-Max Normalization*.
3. Setelah proses normalisasi data, kemudian dilakukan proses *training* data untuk mendapatkan hasil prediksi dan sebagai acuan untuk peramalan harga penutupan saham bulanan Nippon Paint periode berikutnya.
4. Setelah proses *training*, selanjutnya dilakukan proses *testing* untuk mengevaluasi hasil prediksi.

5. Langkah berikutnya yaitu proses denormalisasi pada data untuk membangkitkan nilai yang telah dinormalisasi menjadi nilai asli.
6. Kemudian menentukan nilai peramalan data saham bulanan Nippon Paint untuk beberapa periode kedepan.
7. Menentukan ukuran ketepatan peramalan atau tingkat kesalahan peramalan dengan menggunakan nilai *Mean Absolute Percentage Error* (MAPE).

4.5.2 Diagram Alir Metode *Multilayer Perceptron*

Berikut adalah diagram alir untuk metode *Multilayer Perceptron* (MLP):



Gambar 4.3 Diagram Alir Metode *Multilayer Perceptron*

Berikut adalah langkah-langkah dalam melakukan peramalan menggunakan metode *Multilayer Perceptron* (MLP):

1. *Input* data saham bulanan Nippon Paint periode Januari 2016 sampai dengan Oktober 2021 ke dalam *software* R.

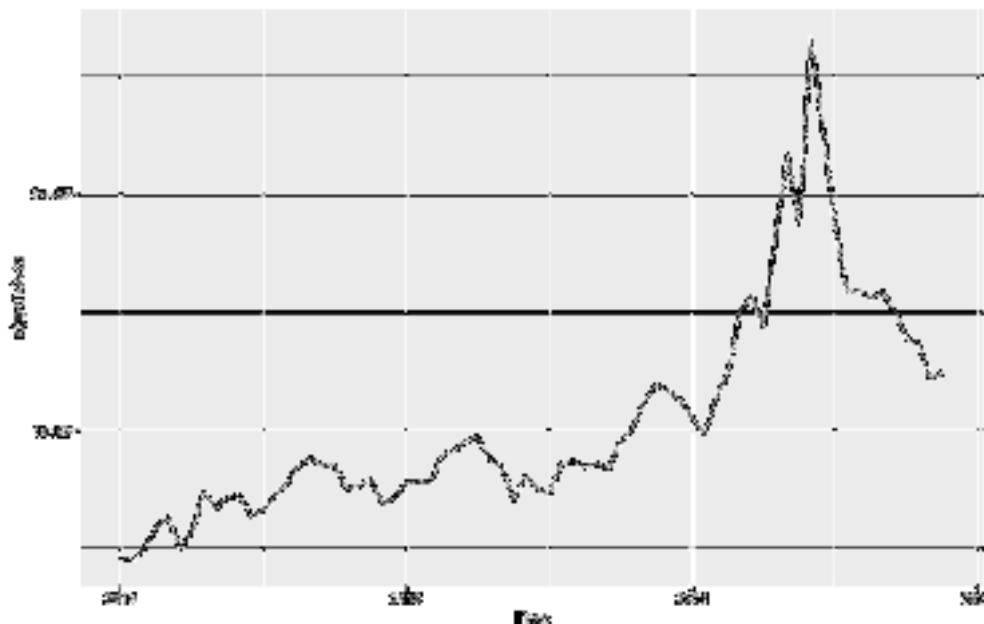
2. Selanjutnya dilakukan proses normalisasi data menggunakan metode *Min-Max Normalization*.
3. Setelah proses normalisasi data, kemudian dilakukan proses pelatihan bobot dan bias sampai terpenuhi parameter untuk mendapatkan hasil prediksi terbaik dan sebagai acuan untuk peramalan harga penutupan saham bulanan Nippon Paint periode berikutnya.
4. Kemudian menentukan nilai peramalan data saham bulanan Nippon Paint untuk beberapa periode kedepan.
5. Menentukan ukuran ketepatan peramalan atau tingkat kesalahan peramalan dengan menggunakan nilai *Mean Absolute Percentage Error* (MAPE).

BAB V

HASIL DAN PEMBAHASAN

5.1. Analisis Deskriptif

Penelitian ini dilakukan dengan menggunakan data harga penutupan saham (*Close*) bulanan dari Nippon Paint yang dimulai dari 1 Januari 2016 sampai dengan 1 Oktober 2021 yaitu sebanyak 70 data. Analisis deskriptif digunakan untuk melihat gambaran umum dari data sebelum melangkah ke metode peramalan *Extreme Learning Machine* dan *Multilayer Perceptron*.



Gambar 5.1 Grafik Data Aktual Harga Penutupan Saham Harian
Nippon Paint

Berdasarkan grafik pada **Gambar 5.1** terlihat bahwa harga penutupan saham bulanan Nippon Paint periode Januari 2016 sampai dengan Oktober 2021 mengalami kenaikan dan penurunan yang berubah-ubah, namun jika dilihat secara keseluruhan berdasarkan tren pergerakan harga penutupan saham bulanan pada periode tersebut cenderung mengalami kenaikan. Diketahui Nippon Paint baru saja merayakan hari jadinya yang ke-140 pada 14 Maret 2021 (Liputan6, 2021), sehingga pada bulan Maret 2021 ada sedikit kenaikan yang terjadi setelah sebelumnya terjadi penurunan

diantara bulan November 2020 sampai dengan bulan Februari 2021 setelah puncak tertinggi pada bulan November 2020.

5.2. Extreme Learning Machine

5.2.1 Pembagian Data Training dan Testing

Pada proses peramalan dengan menggunakan metode ini, dilakukan pembagian data menjadi data *training* dan data *testing*. Pembagian data *training* dan data *testing* dilakukan dengan perbandingan *training:testing* sebesar 10:90, 20:80, 30:70, 40:60, 50:50, 60:40, 70:30, 80:20, dan 10:90 (Nasution, 2015). Berikut pembagian data *training* dan *testing* pada data *Close Price*.

Tabel 5.1 Pembagian Persentase Data *Training* dan *Testing*

<i>Training</i>	<i>Testing</i>
90% (63 Data)	10% (7 Data)

Tabel 5.2 Pembagian Data *Training* dan *Testing*

Bulan	Data Training						Data Testing
	2016	2017	2018	2019	2020	2021	2021
Januari	4.52E+08	6.6E+08	7.81E+08	7.28E+08	1.06E+09	1.88E+09	
Februari	4.52E+08	7.25E+08	7.82E+08	8.56E+08	9.85E+08	1.58E+09	
Maret	4.99E+08	7.75E+08	7.81E+08	8.7E+08	1.13E+09	1.6E+09	
April	5.9E+08	8.55E+08	8.96E+08	8.43E+08	1.24E+09		1.56E+09
Mei	6.32E+08	8.81E+08	9.11E+08	8.6E+08	1.5E+09		1.58E+09
Juni	5E+08	8.5E+08	9.54E+08	8.36E+08	1.57E+09		1.51E+09
Juli	5.69E+08	8.51E+08	9.72E+08	9.51E+08	1.44E+09		1.39E+09
Agustus	7.41E+08	7.5E+08	8.78E+08	1.01E+09	1.82E+09		1.37E+09
September	6.7E+08	7.65E+08	8.48E+08	1.12E+09	2.16E+09		1.22E+09
Oktober	7.16E+08	7.96E+08	7.07E+08	1.19E+09	1.88E+09		1.24E+09
November	7.22E+08	6.9E+08	8.05E+08	1.17E+09	2.67E+09		
Desember	6.37E+08	7.13E+08	7.52E+08	1.13E+09	2.27E+09		

Data hasil untuk proses *training* pada data harga penutupan saham bulanan Nippon Paint adalah sebagai berikut.

Tabel 5.3 Pola *Input Data Training*

	Y	X1	X2	X3	X4	X5	X6	X9
1	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.20252495	-0.25807307


2	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.19508308
3	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.13687704
4	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.20252495
5	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.43269104

51	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.11162791
52	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	0.08770764
53	-0.24318937	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	-0.17009967

Nilai data dari data *input training* yaitu $X_1, X_2, X_3, X_4, X_5, X_6, X_9$ adalah nilai dari data yang digunakan pada analisis ELM yang berjumlah sebanyak 7 *input* berdasarkan hasil dari normalisasi data *training*, nilai dari Y adalah nilai target yang ada pada proses *training* metode *Extreme Learning Machine*.

5.2.2 Arsitektur Jaringan *Extreme Learning Machine*

Berikut merupakan hasil dari jaringan untuk *input* sebanyak 12.



Gambar 5.2 Hasil Arsitektur Jaringan *Close Price*

Gambar 5.2 merupakan hasil arsitektur jaringan data yang akan digunakan dalam proses peramalan nilai penutupan saham bulanan Nippon Paint dengan menggunakan metode *Extreme Learning Machine* (ELM). Berdasarkan langkah-langkah penyelesaian dengan metode ELM, sistem

menerima masukan berupa data historis *close* yang akan menjadi node *input* yaitu sebanyak 7 node dengan asumsi bahwa 7 node *input* ini mewakili 90 persen data penutupan harga saham, sedangkan 1 node sebagai *output* node yang merupakan hasil dari peramalan. Pada proses *training* terdapat nilai bobot *input* yang diinisialisasi secara acak untuk menghitung keluaran pada *hidden node*. *Hidden node* yang digunakan sebanyak 51 yang menunjukkan bahwa pengujian yang dilakukan menggunakan 51 node. Dapat disimpulkan bahwa dengan jumlah *neuron/node* yang banyak maka penghubung antara *input layer* ke *output layer* menjadi banyak sehingga pengenalan pola yang dilakukan sistem semakin baik (Ayustina Giusti, 2018).

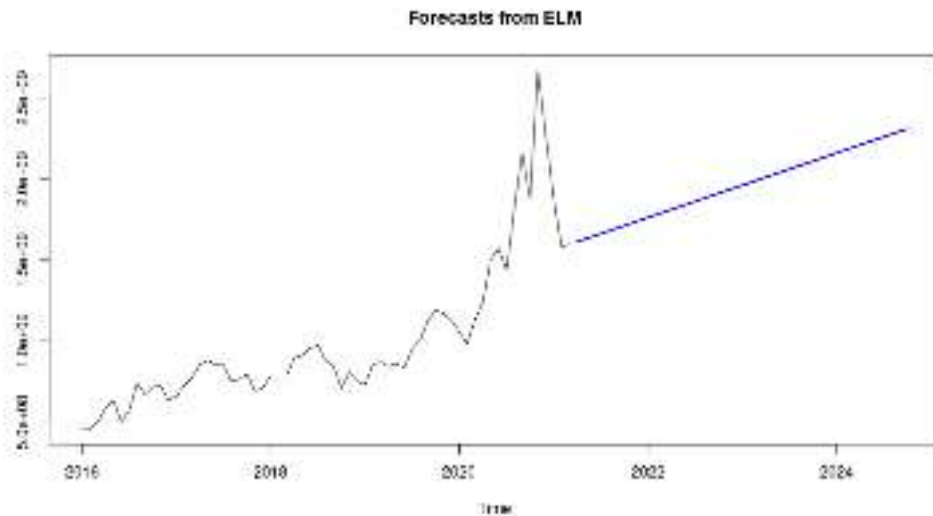
5.2.3 Hasil Peramalan ELM

Berikut ini merupakan hasil peramalan harga penutupan saham bulanan Nippon Paint dengan program *R* menggunakan metode *Extreme Learning Machine*.

Tabel 5.4 Tabel Hasil Peramalan

Tahun	Bulan	Hasil Peramalan	Data Aktual
2021	Desember	1.744.264.151	1.254.000.000
2022	Januari	1.760.849.057	909.000.000
	Februari	1.777.433.962	877.000.000
	Maret	1.794.018.868	-
	April	1.810.603.774	-
	May	1.827.188.679	-
	Juni	1.843.773.585	-
	Juli	1.860.358.491	-
	Agustus	1.876.943.396	-
	September	1.893.528.302	-
	Oktober	1.910.113.208	-
	November	1.926.698.113	-
	Desember	1.943.283.019	-

Berdasarkan hasil peramalan yang didapatkan pada **Tabel 5.4** dapat digambarkan hasil peramalan menggunakan grafik sebagai berikut.



Gambar 5.3 Grafik Hasil Peramalan

Pada **Gambar 5.3** dapat dilihat hasil prediksi yang didapatkan dari data *training* yang digunakan pada metode *Extreme Learning Machine* yang dimana menggunakan data *training* sebanyak 63 data. Terlihat pada sumbu x menunjukkan tahun pada data yang ditampilkan yaitu dari tahun 2016 sampai dengan tahun 2024 sedangkan pada sumbu y diketahui menunjukkan nilai hasil peramalan penutupan sahamnya. Kurva berwarna hitam menggambarkan data *training* dan kurva berwarna biru menggambarkan hasil prediksi nilai penutupan saham.

5.2.4 Perhitungan Nilai Akurasi

Setelah dilakukan analisis dengan metode *Extreme Learning Machine*, maka akan dihitung nilai akurasi hasil peramalan dari analisis ELM yang sudah dilakukan untuk mengetahui apakah analisis yang sudah lakukan layak digunakan, dengan menggunakan program R maka didapatkan nilai *Mean Absolute Percentage Error* (MAPE) sebagai berikut.

Tabel 5.5 Tabel Hasil Nilai Akurasi

Parameter	Nilai
MAPE	11.66649

Berdasarkan hasil perbandingan pada **Tabel 5.5** menunjukkan bahwa metode *Extreme Learning Machine* layak digunakan dalam penelitian

karena memiliki nilai MAPE 10 - 20% yang berarti kemampuan peramalan baik.

5.3. Metode *Multilayer Perceptron*

5.3.1 Pembagian Data *Training* dan *Testing*

Pada proses peramalan dengan menggunakan metode ini, dilakukan pembagian data menjadi data *training* dan data *testing*. Data dibagi menjadi data *training* bertujuan untuk membuat model *machine learning* dan data *testing* digunakan untuk menguji performa dan kebenaran terhadap model yang didapatkan dari data *training*. Berikut merupakan pembagian data *training* dan *testing* pada data *Close Price*.

Tabel 5.6 Pembagian Persentase Data *Training* dan *Testing*

<i>Training</i>	<i>Testing</i>
90% (63 Data)	10% (7 Data)

Tabel 5.7 Pembagian Data *Training* dan *Testing*

Bulan	Data Training						Data Testing
	2016	2017	2018	2019	2020	2021	2021
Januari	4.52E+08	6.6E+08	7.81E+08	7.28E+08	1.06E+09	1.88E+09	
Februari	4.52E+08	7.25E+08	7.82E+08	8.56E+08	9.85E+08	1.58E+09	
Maret	4.99E+08	7.75E+08	7.81E+08	8.7E+08	1.13E+09	1.6E+09	
April	5.9E+08	8.55E+08	8.96E+08	8.43E+08	1.24E+09		1.56E+09
Mei	6.32E+08	8.81E+08	9.11E+08	8.6E+08	1.5E+09		1.58E+09
Juni	5E+08	8.5E+08	9.54E+08	8.36E+08	1.57E+09		1.51E+09
Juli	5.69E+08	8.51E+08	9.72E+08	9.51E+08	1.44E+09		1.39E+09
Agustus	7.41E+08	7.5E+08	8.78E+08	1.01E+09	1.82E+09		1.37E+09
September	6.7E+08	7.65E+08	8.48E+08	1.12E+09	2.16E+09		1.22E+09
Oktober	7.16E+08	7.96E+08	7.07E+08	1.19E+09	1.88E+09		1.24E+09
November	7.22E+08	6.9E+08	8.05E+08	1.17E+09	2.67E+09		
Desember	6.37E+08	7.13E+08	7.52E+08	1.13E+09	2.27E+09		

Data hasil untuk proses *training* pada data harga penutupan saham bulanan Nippon Paint adalah sebagai berikut.

Tabel 5.8 Pola *Input Data Training*

	Y	X1	X2	X3	X4	X5	X6	X9
1	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.20252495	-0.25807307


2	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.19508308
3	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.13687704
4	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.20252495
5	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.20252495	-0.25807307

51	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.11162791
52	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	0.08770764
53	-0.24318937	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	-0.17009967

Nilai data dari data *input training* yaitu $X_1, X_2, X_3, X_4, X_5, X_6, X_9$ adalah nilai dari data yang digunakan pada analisis MLP yang berjumlah sebanyak 7 *input* berdasarkan hasil dari normalisasi data *training*, nilai dari Y adalah nilai target yang ada pada proses *training* metode *Multilayer Perceptron*.

5.3.2 Arsitektur Jaringan *Multilayer Perceptron*

Berikut merupakan hasil jaringan *multilayer perceptron*.



Gambar 5.4 Hasil Arsitektur Jaringan MLP

Gambar 5.4 merupakan hasil arsitektur jaringan data yang akan digunakan dalam proses peramalan nilai penutupan saham bulanan Nippon Paint dengan menggunakan metode *Multilayer Perceptron* (MLP). Berdasarkan langkah-langkah penyelesaian dengan metode MLP, sistem menerima masukan berupa data historis *close* yang akan menjadi node *input* yaitu sebanyak 7

node dengan asumsi bahwa 7 node *input* ini mewakili data penutupan harga saham, sedangkan 1 node sebagai *output* node yang merupakan hasil dari peramalan. Pada proses *training* terdapat nilai bobot *input* yang diinisialisasi secara acak untuk menghitung keluaran pada *hidden* node. *Hidden node* yang digunakan sebanyak 5 yang menunjukkan bahwa pengujian yang dilakukan menggunakan 5 node.

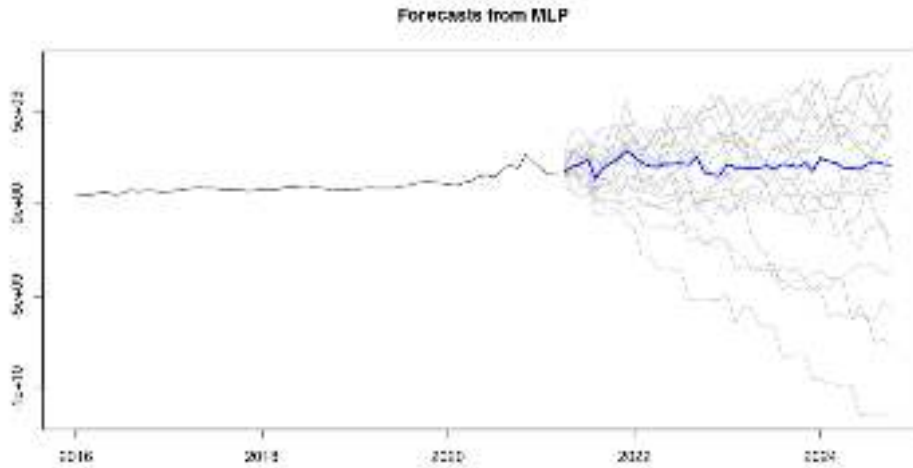
5.3.3 Hasil Peramalan MLP

Berikut ini merupakan hasil peramalan harga penutupan saham bulanan Nippon Paint dengan program *R* menggunakan metode *Multilayer Perceptron*.

Tabel 5.9 Tabel Hasil Peramalan

Tahun	Bulan	Hasil Peramalan	Data Aktual
2021	Desember	2.860.262.833	1.254.000.000
2022	Januari	2.562.730.491	909.000.000
	Februari	2.208.314.489	877.000.000
	Maret	2.020.398.668	-
	April	1.990.107.967	-
	May	2.163.606.840	-
	Juni	2.155.244.694	-
	Juli	2.176.096.780	-
	Agustus	2.124.499.215	-
	September	2.540.294.017	-
	Oktober	1.710.214.978	-
	November	1.579.628.310	-
	Desember	1.549.767.078	-

Berdasarkan hasil peramalan yang didapatkan pada **Tabel 5.9** dapat digambarkan hasil peramalan menggunakan grafik sebagai berikut.



Gambar 5.5 Grafik Hasil Peramalan

Pada **Gambar 5.5** dapat dilihat hasil prediksi yang didapatkan dari data *training* yang digunakan pada metode *Multilayer Perceptron* (MLP) yang dimana menggunakan data *training* sebanyak 63 data. Terlihat pada sumbu x menunjukkan tahun pada data yang ditampilkan yaitu dari tahun 2016 sampai dengan tahun 2024 sedangkan pada sumbu y diketahui menunjukkan nilai hasil peramalan penutupan sahamnya. Kurva berwarna hitam menggambarkan data *training* dan kurva berwarna biru menggambarkan hasil prediksi nilai penutupan saham yang memiliki banyak bayangan yang menggambarkan kemungkinan-kemungkinan hasil prediksi lainnya.

5.3.4 Perhitungan

Setelah dilakukan analisis dengan metode *Multilayer Perceptron*, maka akan dihitung nilai akurasi hasil peramalan dari analisis MLP yang sudah dilakukan untuk mengetahui apakah analisis yang sudah lakukan layak digunakan, dengan menggunakan program R maka didapatkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar sehingga nilai akurasi model MLP sebagai berikut.

Tabel 5.10 Tabel Hasil Nilai Akurasi

Parameter	Nilai
MAPE	4,46143

Berdasarkan hasil perbandingan pada **Tabel 5.10** menunjukkan bahwa metode *Multilayer Perceptron* layak digunakan dalam penelitian karena

memiliki nilai MAPE dibawah 10% yang berarti kemampuan peramalan sangat baik.

5.4. Perbandingan Metode Terbaik

Setelah dilakukan analisis dan didapatkannya nilai akurasi hasil prediksi dari kedua metode yang digunakan yaitu metode *Extreme Learning Machine* (ELM) dan *Multilayer Perceptron* (MLP) akan dilakukan perbandingan nilai keakuratan peramalan dengan menggunakan *Mean Absolute Percentage Error* (MAPE) untuk mengetahui metode mana yang paling tepat yang menghasilkan tingkat kesalahan (*error*) terkecil.

Tabel 5.11 Tabel Hasil Perbandingan Akurasi

Metode	MAPE
ELM	11,67%
MLP	4,46%

Tabel 5.11 merupakan tabel perbandingan akurasi hasil peramalan nilai penutupan saham bulanan Nippon Paint menggunakan metode *Extreme Learning Machine* (ELM) dan *Multilayer Perceptron* (MLP). Secara umum, hasil peramalan menggunakan metode *Extreme Learning Machine* (ELM) dan *Multilayer Perceptron* (MLP) layak digunakan karena memiliki tingkat kesalahan MAPE kurang dari 10% dan 10 – 20%. Berdasarkan hasil perbandingan pada **Tabel 5.11** menunjukkan bahwa metode *Multilayer Perceptron* (MLP) lebih baik digunakan dalam peramalan karena memiliki nilai MAPE yang lebih kecil dibandingkan dengan metode *Extreme Learning Machine* (ELM) dengan tingkat kesalahan peramalan *Mean Absolute Percentage Error* (MAPE) sebesar 4.46%.

BAB VI PENUTUP

6.1. Kesimpulan

Hasil studi kasus Perbandingan Metode *Multilayer Perceptron* (MLP) dan *Extreme Learning Machine* (ELM) Dalam Peramalan Saham Nippon Paint yaitu :

1. Secara umum terlihat bahwa harga penutupan saham bulanan Nippon Paint periode Januari 2016 sampai dengan Oktober 2021 mengalami fluktuasi yang berubah setiap bulannya, namun jika dilihat secara keseluruhan pergerakan harga penutupan saham bulanan pada periode tersebut cenderung mengalami kenaikan.
2. Hasil peramalan penutupan saham bulanan Nippon Paint dengan menggunakan metode terbaik yaitu *Multilayer Perceptron* (MLP) adalah pada bulan Desember 2021 prediksi harga penutupan saham sebesar 2.860.262.833, pada bulan Januari sampai dengan Desember 2022 prediksi harga penutupan saham sebesar 2.562.730.491, 2.208.314.489, 2.020.398.668, 1.990.107.967, 2.163.606.840, 2.155.244.694, 2.176.096.780, 2.124.499.215, 2.540.294.017, 1.710.214.978, 1.579.628.310, 1.549.767.078.
3. Perbandingan nilai akurasi hasil prediksi menggunakan metode *Extreme Learning Machine* (ELM) dan *Multilayer Perceptron* (MLP) berdasarkan nilai MAPE didapatkan hasil bahwa metode MLP lebih tepat digunakan karena memiliki nilai *error* yang lebih kecil dengan tingkat kesalahan peramalan sebesar 4.46%.

6.2. Saran

Berdasarkan kesimpulan yang diperoleh dari analisis, maka diberikan saran sebagai berikut :

1. Bagi calon investor bisa menggunakan metode *Multilayer Perceptron* (MLP) untuk membantu memprediksi harga saham, dan bagaimana kemungkinan yang akan terjadi pada investasi saham calon perusahaan yang diinginkan di masa mendatang. Prediksi harga saham bisa digunakan untuk mengantisipasi penyimpangan harga saham dan membantu investor dalam mengambil keputusan untuk berinvestasi pada suatu perusahaan.
2. Bagi penelitian selanjutnya dapat menggunakan metode lain yang termasuk dalam jaringan saraf tiruan dengan objek penelitian yang sama sehingga dapat dikembangkan dan dapat memberikan hasil beragam dengan kemungkinan lebih akurat pada peramalannya.
3. Bagi penelitian selanjutnya juga dapat dianalisis dengan menggunakan data harian dan tahunan dengan tujuan untuk melihat peramalan jangka pendek serta jangka panjangnya, dengan diharapkannya hasil dari peramalan tersebut dapat menjadi salah satu acuan bagi investor dalam mengambil keputusan untuk berinvestasi pada suatu perusahaan

DAFTAR PUSTAKA

- A. Victor Devadoss, T. A. (2013). Forecasting of Stock Prices Using Multi Layer Perceptron. *International Journal of Computing Algorithm*, 440-449.
- Anand Sharma, S. S. (2015). Forecasting Public Healthcare Services in Jammu & Kashmir Using Time Series Data Mining. *International Journal of Advanced Research in Computer Science and Software Engineering*, vol. 5, no. 12, 570-575.
- Anis Mahfud Al'afi, W. D. (2020). Peramalan Data Time Series Seasonal Menggunakan Metode Analisis Spektral. *Jurnal Siger Matematika*, 10-15.
- Ardilla, Y. (2016). *Metode Hibrida ARIMA dan Multilayer Perceptron untuk Peramalan Jangka Pendek Konsumsi Listrik di Jawa Timur*. Surabaya: ITS.
- Ayu Aryati, I. P. (2020). Peramalan dengan Menggunakan Metode Holt-Winters Exponential Smoothing. *Jurnal EKSPONENSIAL Volume 11, Nomor 1*, 100-106.
- Ayustina Giusti, A. W. (2018). Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2972-2978.
- Azizah. (2020). *Perbandingan metode Holt-Winter's Exponential Smoothing dan Extreme Learning Machine*. Yogyakarta: UNIVERSITAS ISLAM INDONESIA.
- Bosker Sinaga, J. R. (2016). Perancangan Aplikasi Peramalan Penjualan Handphone Dengan Metode Triple Exponential Smoothing. *Jurnal Mantik Penusa*, 55-60.
- Buffa, E. S. (1996). *Manajemen Operasi dan Produksi Modern*. Edisi 8. Jakarta: Binarupa Aksara.

- Chemicals, P. N. (2021, Sept 08). *Latar Belakang*. Diambil kembali dari Nippon Paint - Indonesia: <http://www.nipponpaint-indonesia.com/corporate/tentang-nippon-paint/latar-belakang>
- Christnatalis, R. A. (2019). Perbandingan Metode Multiplicative, Additive dan Double Seasonal Holt-Winters untuk Prediksi Penjualan Mobil. *Jurnal TEKESNOS Vol 1 No 1*, 89-95.
- Cristiane Orquiza Fantina, E. H. (2021). Stock Price Forecast, with Multi Layer Perceptron Artificial Neural Networks. *International Journal of Sciences: Basic and Applied Research (IJSBAR)*, 62-77.
- Dewi, E. A. (2018). *Perbandingan Metode Holt Winter's Exponential Smoothing dan Extreme Learning Machine Pada Peramalan Penjualan Semen*. Yogyakarta: Universitas Islam Indonesia.
- Fausett, L. V. (1994). *Fundamentals of Neural Networks Architectures*. New Jersey: Prentice Hall.
- Hanke, J. &. (2005). *Business Forecasting*. New Jersey: Pearson.
- Hermawan. (2006). *Jaringan Syaraf Tiruan Teori dan Aplikasi*. Yogyakarta: Andi.
- Huang, G. Z. (2012). Extreme Learning Machine for Regression and Multiclass Classification. *IEEE Transactions on systems, man, and cybernetics—PART B: CYBERNETICS, VOL. 42, NO. 2*.
- Irwin Dwi Agustina, W. A. (2009). *Penerapan Metode Extreme Learning Machine untuk Peramalan Permintaan*. Surabaya: ITS.
- Jogiyanto. (2003). *Teori Portofolio dan Analisis Investasi, Edisi III, cet, I*. Yogyakarta: BPFE.
- Johan Saputra, S. F. (2019). Penerapan Metode Triple Exponential Smoothing Untuk Meramalkan Jumlah Penumpang Kereta Api di Daerah Operasi 4 Semarang. *PROSIDING-M33*.
- Kusumadewi, F. (2017). *Peramalan Harga Emas Menggunakan Feedforward Neural Network Dengan Algoritma Backpropagation*. Yogyakarta: UNY.

- Laila Restu Setiya Wati, I. C. (2019). Implementasi Algoritme Extreme Learning Machine (ELM) Untuk Prediksi. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2408-2415 .
- Liputan6. (2021, Apr 04). *140 Tahun Berdiri, Nippon Paint jadi Produsen Cat dengan Sejarah Terpanjang di Jepang*. Diambil kembali dari Liputan 6: <https://www.liputan6.com/citizen6/read/4522987/140-tahun-berdiri-nippon-paint-jadi-produsen-cat-dengan-sejarah-terpanjang-di-jepang>
- Makridakis, S. e. (1988). *Metode dan Aplikasi Peramalan*. Jakarta: Erlangga.
- Makridakis, S. W. (1999). *Metode dan Aplikasi Peramalan*. Jakarta: Binarupa Aksara.
- Modal, B. P. (2003). *Panduan Investasi di Pasar Modal Indonesia*. Jakarta : UFJ Institute.
- Muhammad Iqbal Pratama, P. P. (2018). Peramalan Harga Saham Menggunakan Metode Extreme Learning Machine (ELM) Studi Kasus Saham Bank Mandiri. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5009-5014.
- Nasution, N. D. (2015). Evaluasi Kinerja Akademik Mahasiswa Menggunakan Algoritma Naïve Bayes (Studi Kasus: Fasilkom Unilak). *Jurnal Teknologi Informasi & Komunikasi Digital Zone*. Vol.6, No.2.
- Ni Putu Lilis Indiani, S. K. (2016). PENGARUH VARIABEL TINGKAT KESEHATAN BANK TERHADAP. *E-Jurnal Manajemen Unud*, Vol. 5, No. 5 , 2756 - 2785 .
- Nisa Afida Izati, B. W. (2019). Prediksi Harga Emas Menggunakan Feed Forward Neural Network (FFNN) dengan metode Extreme Learning Machine. *JURNAL GAUSSIAN, Volume 8, Nomor 2*, 171 - 183.
- Noor, F. H. (2007). *Ekonomi Manajerial, Edisi Kesatu* . Jakarta: PT. RajaGrafindo Persada.
- Noor, H. F. (2009). Investasi,. *Pengelolaan Keuangan Bisnis dan Pengembangan*.

- Nurul. (2014, Maret 22). *EXPONENTIAL SMOOTHING*. Diambil kembali dari Nurul MJ: <http://mjnurul.blogspot.com/2014/03/exponential-smoothing.html>
- Ostertag, E. O. (2011). The Simple Exponential Smoothing Mode. *Proc MMS*, 380.
- Primandari, A. H. (2019). *Modul Praktikum Analisis Runtun Waktu*. Yogyakarta: Universitas Islam Indonesia.
- Putu Githa Pratiwi, I. K. (2019). Peramalan Jumlah Tersangka Penyalahgunaan Narkoba Menggunakan Metode Multilayer Perceptron. *MERPATI VOL. 7, NO. 2*, 143-150.
- Reyham Nopriadi Gurianto, I. P. (2016). Peramalan Jumlah Penduduk Kota Samarinda Dengan Menggunakan Metode Pemulusan Eksponensial Ganda dan Tripel Dari Brown. *Jurnal EKSPONENSIAL Volume 7, Nomor 1*.
- Riska Yanu Fa'rifah, Z. B. (2017). Backpropagation Neural Network Untuk Optimasi Pada Prediksi Financial Distress Perusahaan. *Jurnal Instek*, 101-110.
- Rusdiana. (2014). *Manajemen Operasi*. Bandung: CV Pustaka Setia.
- S, K. (2013). *Neuron Fuzzy Integrasi Sistem Fuzzy dan Jaringan Syaraf Tiruan Edisi 2*. Yogyakarta: Graha Ilmu.
- Sari, A. Y. (2020). *Perbandingan Metode Triple Exponential Smoothing dan Metode Extreme Learning Machine dalam Peramalan Indeks Harga Saham Gabungan*. Yogyakarta: UNIVERSITAS ISLAM INDONESIA.
- Soejoeti, Z. (1987). *Analisis Runtun Waktu*. Jakarta: Karunika.
- Sourabh Shastri, A. S. (2015). A Model for Forecasting Tourists Arrival in J&K, India. *International Journal of Computer Applications*, vol. 129, no. 15, 32-36.
- Subagyo, P. (2013). *Forecasting Konsep dan Aplikasi Edisi Ketiga*. Yogyakarta: BPFE- Yogyakarta.
- Supranto. (2001). *Statistik teori dan aplikasi*. Jakarta: Erlangga.

- Suyanto. (2013). *Soft Computing Membangun Mesin Ber IQ Tinggi*. Bandung: Informatika.
- Tendelilin, E. (2001). *Analisis Investasi dan Manajemen Portofolio, Edisi I, cet. I*. Yogyakarta: BPFE.
- Tokopedia, P. (2021). *Harga Penutupan*. Diambil kembali dari Tokopedia Kamus Keuangan: <https://kamus.tokopedia.com/h/harga-penutupan/>
- Tyas Auruma S, I. M. (2013). DIVERSIFIKASI INVESTASI SAHAM: PERBANDINGAN RISIKO TOTAL PORTOFOLIO. *Jurnal Manajemen Teori dan Terapan Tahun 6. No. 1*.
- Umam, K. (2013). *Pasar Modal Syariah dan Praktik Pasar Modal Syariah*. Bandung: Pustaka Setia.
- Vania Onasie, S. W. (2020). Niat Investasi Generasi Milenial Di Pasar Modal. *Jurnal Manajerial dan Kewirausahaan, Volume II No. 2*, 318-326 .
- Walpole, E. &. (1995). *Ilmu Peluang dan Statistika untuk Insinyur dan Ilmuwan* . Bandung: ITB.
- Widodo, T. (2013). *Sistem Neural Untuk Pengelolaan Informasi dan Kendali*. Yogyakarta: Graha Ilmu.
- Wirawan Setialaksana, D. R. (2020). Model Jaringan Syaraf Tiruan dalam Peramalan Kasus Positif Covid-19 di Indonesia. *Jurnal MediaTIK : Jurnal Media Pendidikan Teknik Informatika dan Komputer Vol.3 No.2*, 53-56.

LAMPIRAN

Lampiran 1 Data Penutupan Saham Nippon Paint

Date	Close	Date	Close
01/01/2016	452399994	01/01/2019	728000000
01/02/2016	452200012	01/02/2019	856000000
01/03/2016	499399994	01/03/2019	870000000
01/04/2016	590400024	01/04/2019	843000000
01/05/2016	632000000	01/05/2019	860000000
01/06/2016	500399994	01/06/2019	836000000
01/07/2016	569000000	01/07/2019	951000000
01/08/2016	741000000	01/08/2019	1006000000
01/09/2016	670000000	01/09/2019	1122000000
01/10/2016	716000000	01/10/2019	1190000000
01/11/2016	722000000	01/11/2019	1168000000
01/12/2016	637000000	01/12/2019	1128000000
01/01/2017	660000000	01/01/2020	1056000000
01/02/2017	725000000	01/02/2020	985000000
01/03/2017	775000000	01/03/2020	1132000000
01/04/2017	855000000	01/04/2020	1242000000
01/05/2017	881000000	01/05/2020	1502000000
01/06/2017	850000000	01/06/2020	1568000000
01/07/2017	851000000	01/07/2020	1436000000
01/08/2017	750000000	01/08/2020	1820000000
01/09/2017	765000000	01/09/2020	2162000000
01/10/2017	796000000	01/10/2020	1878000000
01/11/2017	690000000	01/11/2020	2674000000
01/12/2017	713000000	01/12/2020	2266000000
01/01/2018	781000000	01/01/2021	1884000000
01/02/2018	782000000	01/02/2021	1584000000
01/03/2018	781000000	01/03/2021	1595000000
01/04/2018	896000000	01/04/2021	1562000000
01/05/2018	911000000	01/05/2021	1584000000
01/06/2018	954000000	01/06/2021	1508000000
01/07/2018	972000000	01/07/2021	1392000000
01/08/2018	878000000	01/08/2021	1369000000
01/09/2018	848000000	01/09/2021	1217000000
01/10/2018	707000000	01/10/2021	1243000000
01/11/2018	805000000	-	-
01/12/2018	752000000	-	-

Lampiran 2 Program R Studio Extreme Learning Machine

```
library(thief)
library(nnfor)
library(forecast)

# Input Data
nipo = read.csv(file.choose(), sep = ',')
nipo

# Membuat Plot Data Timeseries Untuk Data "ts.nipo"
ts.nipo <- ts(nipo$Close, start = c(2016,1), frequency = 12)
ts.nipo
plot(ts.nipo)

# Pembagian Data
# 60-40 = MAPE 6,34
# 80-20 = MAPE 8,75
# 90-10 = MAPE 11,6 (Hasil Forecast Paling Mendekati)

# Data Training
train = ts(ts.nipo[1:63], start = c(2016,1), frequency = 12)
train

# Data Testing
test = ts(ts.nipo[64:70], start = c(2021,3), frequency = 12)
test

# Fitting EML model
fit.elm <- elm(train)
plot(fit.elm)
fitted(fit.elm)
fit.elm$net$data

forc.elm <- forecast(fit.elm, h = 21)
forc.elm
accuracy(forc.elm)
plot(forc.elm)
```

Lampiran 3 Program R Studio Multilayer Perceptron

```
library(thief)
library(nnfor)
library(forecast)

# Input Data
nipo = read.csv(file.choose(), sep = ';')
nipo

# Membuat Plot Data Timeseries Untuk Data "ts.nipo"
ts.nipo <- ts(nipo$Close, start = c(2016,1), frequency = 12)
ts.nipo
plot(ts.nipo)

# Pembagian Data
# 60-40 = MAPE 0,24 (Test;Start = 43 (2019,7))
# 80-20 = MAPE 6,40 (Test;Start = 57 (2020,8))
# 90-10 = MAPE 4,49 (Test;Start = 64 (2021,3) Hasil Forecast Paling Mendekati)

# Data Training
train = ts(ts.nipo[1:63], start = c(2016,1), frequency = 12)
train

# Data Testing
test= ts(ts.nipo[64:70], start = c(2020,3), frequency = 12)
test

# Fitting MLP Model
fit.mlp <- mlp(train)
plot(fit.mlp)
fitted(fit.mlp)
fit.mlp$net$data

forc.mlp <- forecast(fit.mlp, h = 21)
forc.mlp
accuracy(forc.mlp)
plot(forc.mlp)
```

Lampiran 4 Data Training Extreme Learning Machine

	Y	X1	X2	X3	X4	X5	X6	X9
1	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.20252495	-0.25807307
2	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.19508308
3	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.13687704
4	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.20252495
5	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.43269104
6	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.16664451
7	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.02923588
8	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.35215947
9	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.19667774
10	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.24983389
11	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.37076412
12	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.22724252
13	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.17142857
14	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.19136213
15	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.15149502
16	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.22325581
17	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.29900332
18	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.25647841
19	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.39202658
20	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.23787375
21	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.21661130
22	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.39867110
23	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.22724252
24	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.16744186
25	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.25647841
26	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.25913621
27	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.10498339
28	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23787375
29	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.20066445
30	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.23388704
31	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.38272425
32	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.29767442
33	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.44518272
34	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.12757475
35	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.32823920
36	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.28970100
37	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.08770764
38	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23920266
39	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.29368771
40	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.23521595

41	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.28970100
42	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10498339
43	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.18471761
44	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.10365449
45	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.16744186
46	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.28704319
47	0.19667774	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.31096346
48	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.35348837
49	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.35215947
50	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.17009967	-0.06245847
51	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.11162791
52	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	0.08770764
53	-0.24318937	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	-0.17009967

Lampiran 5 Data Training Multilayer Perceptron

	Y	X1	X2	X3	X4	X5	X6	X9
1	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.20252495	-0.25807307
2	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.43269104	-0.19508308
3	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.16664451	-0.13687704
4	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.02923588	-0.20252495
5	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.35215947	-0.43269104
6	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.19667774	-0.16664451
7	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.24983389	-0.02923588
8	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.37076412	-0.35215947
9	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.22724252	-0.19667774
10	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.17142857	-0.24983389
11	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.19136213	-0.37076412
12	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.15149502	-0.22724252
13	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.22325581	-0.17142857
14	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.29900332	-0.19136213
15	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.25647841	-0.15149502
16	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.39202658	-0.22325581
17	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.23787375	-0.29900332
18	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.21661130	-0.25647841
19	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.39867110	-0.39202658
20	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.22724252	-0.23787375
21	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.16744186	-0.21661130
22	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.25647841	-0.39867110
23	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.25913621	-0.22724252
24	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.10498339	-0.16744186
25	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.23787375	-0.25647841
26	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.20066445	-0.25913621
27	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23388704	-0.10498339
28	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.38272425	-0.23787375
29	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.29767442	-0.20066445
30	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.44518272	-0.23388704
31	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.12757475	-0.38272425
32	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.32823920	-0.29767442
33	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.28970100	-0.44518272
34	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.08770764	-0.12757475
35	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.23920266	-0.32823920
36	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.29368771	-0.28970100
37	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23521595	-0.08770764
38	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.28970100	-0.23920266
39	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.10498339	-0.29368771
40	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.18471761	-0.23521595

41	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10365449	-0.28970100
42	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.16744186	-0.10498339
43	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.28704319	-0.18471761
44	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.31096346	-0.10365449
45	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.35348837	-0.16744186
46	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.35215947	-0.28704319
47	0.19667774	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.06245847	-0.31096346
48	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.11162791	-0.35348837
49	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.17009967	0.08770764	-0.35215947
50	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.17009967	-0.06245847
51	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	-0.43322259	-0.11162791
52	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	0.25249169	0.08770764
53	-0.24318937	-0.65647841	-0.76544850	-0.80000000	0.80000000	-0.63521595	0.19667774	-0.17009967