

Implementasi Metode Extreme Learning Machine untuk Prediksi

Nilai Tukar Rupiah Terhadap US Dollar

(Studi Kasus: Kurs Jual Rupiah Terhadap US Dollar Tahun 2009-2019)

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Program

Studi Statistika



Disusun Oleh:

N a m a : Hani'atul Maghfuroh

NIM : 15611085

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

**HALAMAN PERSETUJUAN PEMBIMBING TUGAS
AKHIR**

**Implementasi Metode Extreme Learning Machine untuk Prediksi
Nilai Tukar Rupiah Terhadap US Dollar**

(Studi Kasus: Nilai Tukar Rupiah Terhadap US Dollar Tahun 2009-2019)

Nama Mahasiswa : Hani'atul Maghfuroh
Nomor Mahasiswa : 15611085

TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI UNTUK
DIUJIKAN

Yogyakarta, 13 Maret 2020

Pembimbing



(Ayundyah Kesumawati, S.Si., M.Si.)

HALAMAN PENGESAHAN
TUGAS AKHIR

Implementasi Metode Extreme Learning Machine untuk Prediksi
Nilai Tukar Rupiah Terhadap US Dollar

(Studi Kasus: Nilai Tukar Rupiah Terhadap US Dollar Tahun 2009-2019)

Nama Mahasiswa : Hani'atul Maghfuroh
Nomor Mahasiswa : 15611085

TUGAS AKHIR INI TELAH DIUJIKAN
PADA TANGGAL
26 Agustus 2020

Nama Penguji

Tanda Tangan

1. R. B. Fajriya Hakim, Dr., S.Si., M.Si.
2. Muhammad Muhajir, S.Si., M.Sc.
3. Ayundyah Kesumawati, S.Si., M.Si.

.....
.....
.....

Mengetahui,

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



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

KATA PENGANTAR



Assalamu 'alaikum Wr. Wb

Puji syukur penulis panjatkan atas kehadiran Allah SWT karena atas berkat, rahmat, kesehatan dan kekuatan yang diberikan oleh-Nya tugas akhir ini dapat berjalan dengan lancar. Tugas akhir ini memberikan begitu banyak pembelajaran yang kemudian dapat di kembangkan pada penelitian selanjutnya.

Keberhasilan pembuatan tugas akhir ini tentunya tidak terlepas dari pihak-pihak yang membantu, memberi semangat dan turut memberi dukungannya selama kegiatan ini berlangsung. Ucapan terima kasih ini disampaikan kepada :

1. Bapak, Ibu, dan Keluarga Besar yang senantiasa mendoakan yang terbaik untuk penulis.
2. Bapak Prof. Riyanto, S.Pd., M.Si., Ph.D. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam UII.
3. Bapak Edy Widodo, Dr., S.Si., M.Si. selaku Ketua Prodi Statistika FMIPA UII.
4. Ibu Ayundyah Kesumawati, S.Si., M.Si. selaku dosen pembimbing yang telah memberikan bimbingan dan pengarahannya.
5. Seluruh pihak yang telah turut mendukung dan membantu jalannya penelitian ini.

Semoga tugas akhir ini dapat bermanfaat bagi penulis khususnya dan bagi semua yang membutuhkan umumnya. Akhir kata, semoga Allah SWT selalu melimpahkan rahmat serta hidayah-Nya kepada kita semua, Amin amin ya robbal 'alamiin.

Wassalamualaikum Wr. Wb

Yogyakarta, 26 Agustus 2020

Hani'atul Maghfuroh

HALAMAN PERSEMBAHAN

Tugas akhir ini penulis persembahkan untuk orang-orang berikut:

1. Ibu Ayundyah Kesumawati, S.Si, M.Si. selaku dosen pembimbing tugas akhir yang sudah membimbing saya dengan sabar. Mengajari saya ilmu yang tidak bisa terbayarkan, mengajari saya artinya berjuang untuk mendapatkan sesuatu yang diinginkan. Terima kasih ibu, jasamu akan saya kenang selalu, ilmu yang ibu berikan akan saya terapkan seumur hidup saya.
2. Bapak Subiyanto dan Ibu Nurrohimah, selaku Bapak dan Ibu saya yang selalu mendoakan dan berjuang mencari nafkah buat anaknya. Terima kasih untuk semua yang telah diberikan kepada saya walaupun sampai kapanpun saya tidak bisa membalas budi kepada orang tua. Semoga karya ini bisa menjadi hadiah terindah meskipun masih banyak kekurangan.
3. Muhammad Faiz Abid Ahnafi, adik laki-laki saya tercinta. Terima kasih atas segala dukungan dan hiburan yang telah diberikan. Semoga adikku kedepannya semakin sukses dan dipermudah segala urusanya.
4. Sahabat tercinta saya yaitu Meila, Zulfa, Tyaa Ali, Aulia, Hita, Anggi, dan Buyut yang selalu mendukung, mendoakan, memberi semangat dan mendengarkan keluh kesah saya dalam keadaan apapun.
5. Teman sebimbingan saya yaitu Meila, Listari, Nita, Nida, Meymunah, Mimi, Amdhu, Rhesa yang selalu memberi semangat saat pengerjaan tugas akhir.
6. Teman saya yaitu Abdul Azis yang selalu memberi semangat dan selalu ada untuk sayadikala suka ataupun duka.
7. Teman-teman seperjuangan Statistika 2015, terima kasih banyak atas kebersamaan dan dukungannya.
8. Semua pihak yang tidak dapat disebutkan satu per satu, terima kasih.

HALAMAN PERNYATAAN

Dengan ini menyatakan bahwa dalam skripsi ini tidak terdapat karya yang pernah diajukan untuk memperoleh gelar kesarjanaan disuatu Perguruan Tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain kecuali yang secara tertulis diacu dalam naskah ini dan diterbitkan dalam daftar pustaka.

Yogyakarta, 26 Agustus 2020

Penulis



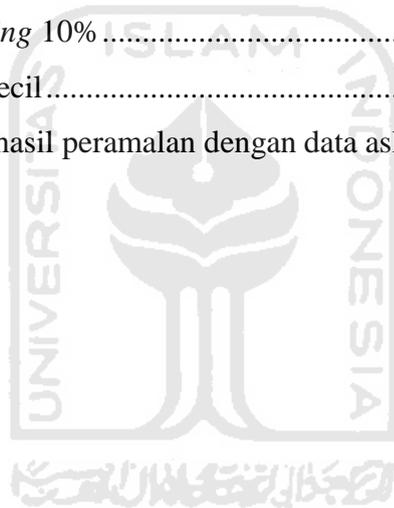
Hani'atul Maghfuroh

DAFTAR ISI

HALAMAN JUDUL.....	1
HALAMAN PERSETUJUAN PEMBIMBING TUGAS AKHIR	2
HALAMAN PENGESAHAN TUGAS AKHIR.....	1
KATA PENGANTAR	1
HALAMAN PERSEMBAHAN.....	1
HALAMAN PERNYATAAN	1
DAFTAR ISI.....	1
DAFTAR GAMBAR	1
INTISARI.....	2
ABSTRACT.....	1
BAB I.....	1
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	1
1.3 Batasan Masalah.....	1
1.4 Tujuan Penelitian.....	1
1.5 Manfaat Penelitian.....	1
BAB II TINJAUAN PUSTAKA.....	2
BAB III LANDASAN TEORI.....	7
3.1 Nilai Tukar	7
3.1.1 Macam-Macam Kurs	8
3.1.2 Faktor-faktor yang Mempengaruhi Kurs.....	8
3.2 Peramalan	10
3.3 Jaringan Saraf Tiruan (JST)	11
3.4 <i>Extreme Learning Machine</i> (ELM).....	12
3.5 <i>Data Training</i> dan <i>Data Testing</i>	15
3.6 <i>Double Exponential Smoothing</i> (DES)..... Error! Bookmark not defined.	
3.7 Evaluasi Kinerja Peramalan	15
3.7.1 <i>Mean Square Error</i> (MSE).....	15
BAB IV METODOLOGI PENELITIAN.....	16
4.1 Populasi dan Sampel	16
4.2 Sumber Data	16
4.3 Variabel Penelitian	16
4.4 Metode Analisis Data	16
BAB V HASIL DAN PEMBAHASAN.....	18
5.1 Analisis Deskriptif.....	18
5.2 Peramalan <i>Extreme Learning Machine</i>	19
BAB VI.....	41
PENUTUP	41
Daftar Pustaka	42
LAMPIRAN	44

DAFTAR TABEL

Tabel 2. 1 Penelitian terdahulu	4
Tabel 4. 1 Variabel Penelitian	16
Tabel 5. 1 Pembagian Data <i>Training</i> dan <i>Testing</i>	19
Tabel 5. 2 Nilai MSE <i>training</i> 75%	27
Tabel 5. 3 Nilai MSE <i>training</i> 80%	28
Tabel 5. 4 Nilai MSE <i>training</i> 90%	28
Tabel 5. 5 Nilai MSE terkecil	28
Tabel 5. 6 Nilai MSE <i>testing</i> 25%	36
Tabel 5. 7 Nilai MSE <i>testing</i> 20%	37
Tabel 5. 8 Nilai MSE <i>testing</i> 10%	37
Tabel 5. 9 Nilai MSE terkecil	37
Tabel 5. 10 Perbandingan hasil peramalan dengan data asli	38



DAFTAR GAMBAR

Gambar 4. 1 <i>Flowchart</i> Penelitian.....	17
Gambar 5. 1 Pergerakan Kurs Jual dari Januari 2009- Juni 2019	18
Gambar 5. 2 Arsitektur jaringan <i>hidden layer</i> 5 pada data <i>training</i> 75%.....	20
Gambar 5. 3 Arsitektur jaringan <i>hidden layer</i> 10 pada data <i>training</i> 75%	21
Gambar 5. 4 Arsitektur jaringan <i>hidden layer</i> 15 pada data <i>training</i> 75%	21
Gambar 5. 5 Arsitektur jaringan <i>hidden layer</i> 20 pada data <i>training</i> 75%	22
Gambar 5. 6 Arsitektur jaringan <i>hidden layer</i> 5 pada data <i>training</i> 80%.....	22
Gambar 5. 7 Arsitektur jaringan <i>hidden layer</i> 10 pada data <i>training</i> 80%	23
Gambar 5. 8 Arsitektur jaringan <i>hidden layer</i> 15 pada data <i>training</i> 80%	24
Gambar 5. 9 Arsitektur jaringan <i>hidden layer</i> 20 pada data <i>training</i> 80%	24
Gambar 5. 10 Arsitektur jaringan <i>hidden layer</i> 5 pada data <i>training</i> 90%.....	25
Gambar 5. 11 Arsitektur jaringan <i>hidden layer</i> 10 pada data <i>training</i> 90%.....	25
Gambar 5. 12 Arsitektur jaringan <i>hidden layer</i> 15 pada data <i>training</i> 90%.....	26
Gambar 5. 13 Arsitektur jaringan <i>hidden layer</i> 20 pada data <i>training</i> 90%.....	27
Gambar 5. 14 Arsitektur jaringan <i>hidden layer</i> 5 pada data <i>testing</i> 25%	29
Gambar 5. 15 Arsitektur jaringan <i>hidden layer</i> 10 pada data <i>testing</i> 25%	30
Gambar 5. 16 Arsitektur jaringan <i>hidden layer</i> 15 pada data <i>testing</i> 25%	30
Gambar 5. 17 Arsitektur jaringan <i>hidden layer</i> 20 pada data <i>testing</i> 25%	31
Gambar 5. 18 Arsitektur jaringan <i>hidden layer</i> 5 pada data <i>testing</i> 20%	31
Gambar 5. 19 Arsitektur jaringan <i>hidden layer</i> 10 pada data <i>testing</i> 20%	32
Gambar 5. 20 Arsitektur jaringan <i>hidden layer</i> 15 pada data <i>testing</i> 20%	33
Gambar 5. 21 Arsitektur jaringan <i>hidden layer</i> 20 pada data <i>testing</i> 20%	33
Gambar 5. 22 Arsitektur jaringan <i>hidden layer</i> 5 pada data <i>testing</i> 10%	34
Gambar 5. 23 Arsitektur jaringan <i>hidden layer</i> 10 pada data <i>testing</i> 10%	34
Gambar 5. 24 Arsitektur jaringan <i>hidden layer</i> 15 pada data <i>testing</i> 10%	35
Gambar 5. 25 Arsitektur jaringan <i>hidden layer</i> 10 pada data <i>testing</i> 10%	36
Gambar 5. 26 Perbandingan data asli dan hasil peramalan kurs jual	39
Gambar 5. 27 Grafik hasil peramalan kurs jual.....	40

Implementasi Metode Extreme Learning Machine untuk Prediksi Nilai Tukar Rupiah Terhadap US Dollar

(Studi Kasus: Nilai Tukar Rupiah Terhadap US Dollar Tahun 2009-2019)

Hani'atul Maghfuroh

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

INTISARI

Indonesia pada saat ini sedang mengalami pelemahan nilai tukar rupiah terhadap dolar Amerika. Hal tersebut membawa dampak positif dan negatif. Oleh karena itu, prediksi terhadap nilai tukar rupiah menggunakan suatu analisis yang tepat sangat penting. Diperlukan sistem yang dapat memprediksi nilai tukar mata uang secara efektif dan efisien. Pada Jaringan Syaraf Tiruan yang telah diketahui lebih baik dari metode yang lainnya ternyata dapat dikembangkan lagi metodenya untuk peramalan. Untuk itu, ditemukan Extreme Learning Machine (ELM) yang merupakan metode pembelajaran dalam JST. Penelitian ini bertujuan untuk mengetahui hasil implementasi metode ELM pada nilai tukar Rupiah terhadap US Dollar pada tahun 2009 – 2019, dan untuk mengetahui hasil prediksi nilai kurs bulan Juli tahun 2019. Hasil dari penelitian menunjukkan pada umumnya nilai tukar kurs jual dari bulan Januari tahun 2009 sampai dengan bulan Juni tahun 2019 mengalami fluktuasi. Dari hasil evaluasi kinerja peramalan didapatkan nilai MSE terkecil yaitu sebesar 2319.92, yang berarti bahwa kombinasi terbaik terdapat dalam data testing 25% dengan hidden layer 20 dan kombinasi rep 15.

Kata Kunci : Nilai Tukar, Prediksi, Extreme Learning Machine (ELM).

**Implementation of the Extreme Learning Machine Method for
Predicting Rupiah Exchange Rates against US Dollars**
(Case Study: Rupiah Exchange Rate Against Dollar in 2009-2019)

Hani'atul Maghfuroh

Department Statistics, Faculty of Mathematics and Natural Science
Islamic University of Indonesia

ABSTRACT

Indonesia is currently experiencing a weakening of the Indonesian rupiah exchange rate against the US dollar. The weakening of the rupiah has positive and negative impacts. Therefore, it is important to predict the exchange rate of the rupiah using an appropriate analysis. To simplify the process of predicting currency rates, we need a system that is able to predict the next exchange rate effectively and efficiently. Many methods are used to get accurate forecast results. In Artificial Neural Networks that have been known to be better than other methods, it turns out that methods for forecasting can be developed. For this reason, a learning method is found in ANN called Extreme Learning Machine (ELM). This study aims to determine the results of the implementation of the ELM method on the exchange rate of the Rupiah against the US Dollar in 2009 - 2019, and to find out the results of the prediction of the exchange rate in July 2019. The results of the study indicate in general the exchange rate of the selling rate from January 2009 to with June 2019 experiencing fluctuations. From the results of forecasting performance evaluation obtained the smallest MSE value that is equal to 2319.92, which means that the best combination is in the 10% testing data with hidden layer 20 and rep combination of 15.

Keywords: Exchange Rates, Predictions, Extreme Learning Machine (ELM).

BAB I

PENDAHULUAN

1.1 Latar Belakang

Nilai tukar rupiah Indonesia terhadap dolar Amerika saat ini sedang melemah. Hal tersebut membawa dampak positif dan negatif (Aprilliani, 2015). Dampak positifnya adalah pertama, kinerja ekspor akan meningkat. Ini jadi penyeimbang menurunnya performa impor di tengah pelemahan rupiah. Contoh kompetitifnya harga produk dalam negeri sudah terlihat di kinerja ekspor Mei 2018. Pada bulan Mei, rata-rata harga agregat produk ekspor non migas mencapai USD 305,3 juta per ton. Jumlah tersebut turun 4,99% dibandingkan Mei 2017 yang mencapai USD 321,4 juta per ton. Industri dalam negeri memiliki kesempatan lebih besar untuk mendongkrak ekspor karena melemahnya nilai tukar rupiah mengakibatkan harga lokal lebih murah.

Pelemahan rupiah juga berdampak positif terhadap sektor pariwisata. Akibat adanya pelemahan rupiah, turis dari Amerika bisa mendapat rupiah dalam jumlah lebih banyak dari biasanya bisa. Hal ini tentunya lebih menarik minat turis asing untuk berkunjung ke Indonesia. Mereka memiliki daya beli yang lebih besar untuk berbelanja. Bersamaan dengan itu, sektor pariwisata kita juga jadi semakin ramai dikunjungi.

Dampak negatif melemahnya nilai tukar rupiah dapat mengakibatkan melambatnya pertumbuhan ekonominya pada kuartal II-2015 mengalami perlambatan, dengan tumbuh sebesar 4,6 persen. Angka ini menurun jika dibandingkan pertumbuhan ekonomi pada kuartal I-2015 sebesar 4,7 persen. (Umar, 2015). Mengakibatkan menurunnya daya beli, contohnya pada tahun 2015 penurunan rupiah yang mencapai lebih dari Rp13.000 per dollar menyebabkan

kenaikan harga barang, terutama yang mengandalkan bahan baku impor. Seperti disampaikan Direktur INDEF Enny Sri Hartati. Kenaikan barang dan juga tarif listrik, serta transportasi membuat konsumen mengurangi belanja barang yang bukan merupakan kebutuhan pokok. Dia mengatakan penurunan daya beli ini lebih banyak dirasakan oleh masyarakat kelas menengah kebawah, jadi tidak heran jika di pusat perbelanjaan besar masih terjadi antrian panjang pembeli barang (Lestari, 2015). Tidak hanya itu, melemahnya nilai tukar rupiah juga sangat berdampak buruk terhadap ekonomi, sehingga penstabilkan nilai tukar merupakan kebijakan ekonomi yang penting pada beberapa negara (Simorangkir, 2004).

Nilai tukar mata uang bernilai fluktuatif (Simorangkir, 2004). Untuk proses prediksi nilai tukar mata uang diperlukan sistem yang mampu memprediksi secara efektif dan efisien. Hal tersebut dapat membantu menentukan kebijakan ataupun strategi-strategi kedepan. Telah banyak dibangun sistem prediksi pada bidang-bidang lain seperti sistem prediksi curah hujan, prediksi harga bahan pokok, dan sebagainya. Banyaknya permasalahan khususnya tentang peramalan atau prediksi dengan data deret waktu, maka diperlukan metode yang dapat mengimplementasikan sistem tersebut. Banyak metode yang digunakan untuk memperoleh hasil prediksi yang baik dan akurat. Metode-metode tersebut diantaranya adalah dengan Arch, Garch, Jaringan Syaraf Tiruan (JST), dan lain-lain. Pada Jaringan Syaraf Tiruan yang telah diketahui lebih baik dari metode yang lainnya ternyata dapat dikembangkan lagi metodenya untuk melakukan prediksi. Tetapi ditakutkan metode yang sebelumnya semakin ditinggalkan karena membutuhkan waktu lama untuk pengambilan keputusan. Untuk mengatasi masalah, (Huang, 2004) menemukan *Extreme Learning Machine* (ELM) yang merupakan metode pembelajaran dalam JST.

Extreme Learning Machine (ELM) digunakan untuk mengatasi kelemahan JST yaitu dalam *learning speed*. Metode tersebut merupakan metode pembelajaran baru dari JST yang menggunakan Single Hidden Layer Feedforward Neuron Networks (SLFNs). (Fikriya & dkk, 2017)

Berdasarkan hal tersebut, penulis tertarik melakukan penelitian yang berjudul “Prediksi Nilai Tukar Rupiah Terhadap US Dollar Menggunakan Metode Extreme Learning Machine (Studi Kasus: Nilai Tukar Rupiah Terhadap Dollar Tahun 2009-2019)” yang diharapkan dapat membantu pihak-pihak terkait menentukan kebijakan untuk kedepannya dengan baik.

1.2 Rumusan Masalah

Berdasarkan uraian dari latar belakang masalah di atas maka diperoleh rumusan masalah sebagai berikut:

1. Bagaimana hasil implementasi metode ELM pada nilai tukar Rupiah terhadap US Dollar pada tahun 2009 - 2019?
2. Bagaimana tingkat akurasi dari hasil prediksi nilai tukar Rupiah terhadap US Dollar pada bulan Juli tahun 2019?

1.3 Batasan Masalah

Batasan masalah pada penelitian adalah:

1. Data yang digunakan yaitu data Bank Indonesia dari tahun 2009 sampai tahun 2019.
2. Menggunakan metode *Extreme Learning Machine*.
3. *Software* yang digunakan adalah *R*.

1.4 Tujuan Penelitian

Penelitian ini memiliki tujuan sebagai berikut:

1. Untuk mengetahui hasil implementasi metode ELM pada kurs Rupiah terhadap US Dollar pada tahun 2009 – 2019.

2. Untuk mengetahui tingkat akurasi dari hasil prediksi kurs Rupiah terhadap US Dollar pada bulan Juli tahun 2019.

1.5 Manfaat Penelitian

Adapun manfaat penelitian ini adalah sebagai berikut:

1. Memberikan informasi hasil prediksi nilai tukar dan juga sebagai bahan pertimbangan bagi instansi terkait untuk menentukan kebijakan kedepannya.
2. Sebagai salah satu sarana informasi dan referensi bagi semua pihak yang tertarik dengan masalah yang dibahas dalam penelitian ini.



BAB II TINJAUAN PUSTAKA

Sebelumnya ada beberapa penelitian yang mempunyai keterkaitan dengan penelitian ini. Berikut beberapa penelitian terdahulu.

Penelitian berjudul “Mendiagnosis Penyakit Diabetes Melitus Dengan Menggunakan Metode Extreme Learning Machine” oleh (Pangaribuan, 2016). Adapun tujuan dari penelitian ini adalah implementasi ELM untuk diagnosis penyakit diabetes melitus serta menganalisis keakuratan hasil diagnosis. *Data set* diabetes yang digunakan pada penelitian ini adalah *data set* bersifat klasifikasi (*classification*) yang diambil dari UCI Repository. *Data set* ini terdiri dari populasi wanita yang berumur paling muda 21 tahun dan tinggal di daerah Phoenix, Arizona. *Data set* diambil menurut kriteria *World Health Organization* (WHO), dimana ada total 768 orang yang diambil menjadi *data set* pada penelitian ini yang nantinya akan dibagi menjadi data *training* dan data *testing*. Jika dilihat dari hasil eksperimen yang sebelumnya telah dilakukan, terlihat bahwa metode ELM mampu menghasilkan tingkat akurasi prediksi yang baik dengan kecepatan prediksi yang sangat baik. Untuk ELM, MSE pada data *testing* adalah 0.4036 dan tingkat kesalahan MSE untuk *backpropagation* pada data *testing* adalah 0.9425.

Penelitian yang dilakukan oleh (Alfiyatin & dkk, 2019) yang berjudul “Penerapan Extreme Learning Machine (ELM) Untuk Peramalan Laju Inflasi Di Indonesia”. Data diperoleh dari Bank Indonesia (Indonesia 2017) dan Badan Pusat Statistik (BPS). Menggunakan data dari bulan Januari 2005 – Desember 2017. Faktor-faktor yang digunakan dalam penelitian ini yaitu IHK, tingkat suku bunga, jumlah uang beredar, nilai tukar rupiah, nilai kredit dan nilai aset.

Parameter tersebut dijadikan sebagai variabel input pada peramalan laju inflasi sedangkan variabel output berupa hasil peramalan tingkat inflasi di Indonesia. Berdasarkan hasil pengujian yang telah dilakukan, metode ELM mendapatkan nilai kesalahan sebesar 0.0202008, sedangkan dengan metode *backpropagation* sebesar 1.16035821. Hal tersebut membuktikan bahwa metode ELM sangat cocok digunakan untuk peramalan karena nilai kesalahannya lebih kecil.

Berikutnya adalah penelitian yang dilakukan oleh (Ayustina Giusti, 2017) yang berjudul “Prediksi Penjualan Mi Menggunakan Metode *Extreme Learning Machine* (ELM) di Kober Mie Setan Cabang Soekarno Hatta”. Tujuan dari penelitian ini adalah memprediksi penjualan restoran Kober Mie Setan, dari penelitian sebelumnya prediksi dengan metode ELM menunjukkan tingkat kesalahan yang kecil sehingga sangat cocok untuk memprediksi jumlah permintaan konsumen terhadap menu restoran Kober Mie Setan. Proses prediksi penjualan mi di Kober Mie Setan yaitu normalisasi data, proses *training*, proses *testing*, denormalisasi data, dan perhitungan nilai *error* menggunakan *Mean Square Error* (MSE). Berdasarkan pengujian yang dilakukan untuk mengetahui perbedaan penggunaan fitur data dalam penelitian ini menghasilkan tingkat *error* terkecil yaitu 0.0171 dengan menggunakan fitur data historis dan fitur data sisa penjualan.

Penelitian berikutnya dilakukan (Agustina, 2010) dengan judul “Penerapan Metode *Extreme Learning Machine* untuk Peramalan Permintaan”. Pada penelitian ini penulis akan membuat sistem peramalan permintaan dengan menerapkan metode *ELM*. Metode ini merupakan salah satu metode pembelajaran baru dari jaringan syaraf tiruan. Hasil uji coba dalam penelitian ini menunjukkan bahwa metode *ELM* memiliki tingkat akurasi yang lebih baik dibandingkan dengan metode konvensional seperti *Moving Average* dan *Exponential Smoothing*. Dengan implementasi metode *ELM* untuk peramalan permintaan ini diharapkan mampu membantu para pelaku industri dalam menentukan jumlah permintaann secara lebih akurat dan efektif.

Penelitian selanjutnya dilakukan oleh (Fikriya & dkk, 2017) dengan judul “Implementasi *Extreme Learning Machine* untuk Pengenalan Objek Citra

Digital”. Tujuan dari penelitian ini adalah untuk mengetahui kemampuan klasifikasi *ELM* pada pengenalan objek citra digital. *ELM* untuk pengenalan objek citra digital pada penelitian ini terdiri dari 2500 node pada input layer, 1250 node pada hidden layer, dan 3 node pada output layer. Dataset dikelompokkan berdasarkan ukuran objek dalam citra. Hasil uji coba dan evaluasi model dengan data testing menghasilkan tingkat akurasi sebesar 57,33% pada citra dengan objek berukuran kecil, 81,33% pada citra dengan objek berukuran sedang, dan 74,67% pada citra dengan objek berukuran besar.

Perbedaan penelitian ini dengan penelitian yang sebelumnya yaitu pada penelitian ini menggunakan data nilai tukar Rupiah terhadap Dollar Amerika yang kemudian dianalisis dengan menggunakan metode *Extreme Learning Machine* (ELM). Tujuan penelitian ini adalah untuk memprediksi nilai tukar Rupiah terhadap Dollar Amerika. Dikarenakan subjek, objek dan tempat penelitian memiliki perbedaan, maka penulis tertarik melakukan penelitian tentang “Prediksi Nilai Tukar Rupiah Terhadap US Dollar Menggunakan Metode Extreme Learning Machine (Studi Kasus: Nilai Tukar Rupiah Terhadap US Dollar Tahun 2009-2019)”.

Tabel 2. 1 Penelitian terdahulu

Nama	Judul	Variabel	Metode	Kesimpulan
(Pangaribuan, 2016)	Mendiagnosis Penyakit Diabetes Melitus Dengan Menggunakan Metode Extreme Learning Machine	Umur	Extreme Learning Machine	Metode ELM mampu memberikan hasil akurasi yang baik dengan MSE untuk ELM data <i>testing</i> adalah 0.4036 dan MSE untuk <i>backpropagation</i> pada data <i>testing</i> adalah 0.9425.

(Alfiyatin & dkk, 2019)	Penerapan Extreme Learning Machine Untuk Peramalan Laju Inflasi Di Indonesia	Laju inflasi	Extreme Learning Machine	Metode ELM mendapatkan nilai kesalahan sebesar 0.0202008, lebih kecil dibandingkan dengan metode <i>backpropagation</i> sebesar 1.16035821. Hal tersebut membuktikan bahwa metode ELM sangat cocok digunakan untuk peramalan.
(Ayustina Giusti, 2017)	Prediksi Penjualan Mi Menggunakan Metode <i>Extreme Learning Machine</i> Di Kober Mie Setan Cabang Soekarno Hatta	Penjualan produk mi dan sisa penjualan	Extreme Learning Machine	Penelitian ini menghasilkan tingkat <i>error</i> terkecil yaitu 0.0171, menggunakan fitur data historis dan fitur data sisa penjualan.
(Agustina, 2010)	Penerapan Metode Extreme Learning Machine untuk Peramalan Permintaan	Penjualan kaos dan pin	Extreme Learning Machine	Hasil uji coba dalam penelitian menunjukkan bahwa metode <i>ELM</i> memiliki tingkat akurasi yang lebih baik daripada metode konvensional seperti <i>Moving Average</i> dan <i>Exponential Smoothing</i> .

(Fikriya & dkk, 2017)	Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital	Gambar guci, kelinci, mobil, sepatu, dan sepeda.	Extreme Learning Machine	Hasil uji coba dan evaluasi model dengan data testing menghasilkan tingkat akurasi sebesar 57,33% pada citra dengan objek berukuran kecil, 81,33% pada citra dengan objek berukuran sedang, dan 74,67% pada citra dengan objek berukuran besar.
Maghfuroh (2019)	Prediksi Nilai Tukar Rupiah Terhadap US Dollar Menggunakan Metode Extreme Learning Machine	Kurs jual	Extreme Learning Machine	Dari hasil penelitian didapatkan nilai MSE terkecil yaitu sebesar 2319.92, yang berarti bahwa kombinasi terbaik terdapat dalam data <i>testing</i> 10% dengan <i>hidden layer</i> 20 dan kombinasi <i>rep</i> 15. Dari hasil tersebut didapatkan hasil peramalan yang akurat dan tidak jauh berbeda dengan data aktual.

BAB III

LANDASAN TEORI

3.1 Nilai Tukar

Nilai tukar (atau dikenal sebagai kurs) merupakan harga mata uang dari suatu negara terhadap mata uang negara lain. Perbandingan nilai merupakan sebutan lain dari kurs. Artinya, ketika terjadi pertukaran antara dua mata uang yang berbeda, maka akan menghasilkan perbandingan nilai atau harga dari kedua mata uang tersebut. Kurs mempunyai peran penting dalam hal bertransaksi. Hal itu karena kurs dapat membantu menerjemahkan harga-harga dengan mata uang yang berbeda dari berbagai negara. Kurs juga memiliki peran yang penting di pasar valuta asing (*foreign exchange market*) atau yang dikenal dengan nama “*Forex*”. Terjadi pertukaran mata uang dengan kurs yang disepakati oleh beberapa pihak yang terjadi di pasar valuta asing. (Thionita, 2018)

Kurs dapat mengalami dua macam perubahan, yaitu apresiasi dan depresiasi. Kenaikan nilai mata uang sendiri terhadap mata uang asing disebut apresiasi, hal tersebut terjadi karena di pasar valuta asing terdapat daya tarik menarik yang kuat antara permintaan dan penawaran. Ekspor menjadi lebih mahal dan impor menjadi lebih murah jika mata uang mengalami apresiasi terhadap mata uang lainnya. Sedangkan depresiasi adalah peristiwa menurunnya nilai mata uang sendiri terhadap mata uang asing. Ekspor menjadi lebih murah dan impor menjadi lebih mahal jika terjadi depresiasi mata uang dengan mata uang lainnya. (Thionita, 2018)

Nilai kurs merupakan data deret waktu (*time series*) karena nilainya bisa berubah pada setiap harinya, perubahan tersebut bisa disebabkan oleh kondisi prekonomian dunia dan dalam negeri, juga oleh kondisi sosio-politik. (Mulyana, 2014) Dalam *time series* terdapat beberapa macam pola data dan nilai kurs termasuk dalam pola data siklis karena data dipengaruhi oleh fluktuasi ekonomi.

3.1.1 Macam-Macam Kurs

Kurs terdapat 3 macam (Thionita, 2018), yaitu:

1. Kurs Beli.

Kurs yang digunakan oleh bank merupakan kurs beli, selain itu kurs beli juga digunakan dalam penukaran uang asing (*money changer*). Harga beli mata uang asing yang dilakukan oleh bank, penukaran mata uang asing, dan pedagang valuta asing merupakan pengertian kurs beli secara singkat. Sebagai contoh, jika kita ingin menukarkan US\$100 yang kita miliki dengan rupiah, maka kurs yang kita gunakan adalah kurs beli.

2. Kurs Jual

Secara singkat, kurs jual dapat diartikan sebagai harga jual mata uang valuta asing oleh bank, penukaran uang asing (*money changer*), dan para pedagang valuta asing. Sebagai contoh, jika kita ingin menukarkan rupiah dengan dolar Singapura, maka kurs yang kita gunakan adalah kurs jual.

3. Kurs Tengah

Kurs tengah adalah kurs di antara kurs jual dan kurs beli. Kurs tengah didapatkan dengan cara menjumlah kurs jual dan kurs beli lalu di bagi dua.

3.1.2 Faktor-faktor yang Mempengaruhi Kurs

Berikut merupakan faktor-faktor yang mempengaruhi kurs:

1. Tingkat Inflasi

Kenaikan harga barang atau jasa adalah penjelasan inflasi secara sederhana. Nilai mata uang suatu negara yang menurun juga merupakan inflasi. Perdagangan internasional barang atau jasa merupakan dasar utama yang ada dalam pasar valuta asing. Hal tersebut mengakibatkan harga dalam negeri terhadap harga luar negeri memiliki perubahan. Hal tersebut dapat disebut sebagai faktor penggerak kurs valuta asing.

Amerika Serikat bekerjasama dengan Indonesia dalam perdagangan adalah contohnya. Permintaan terhadap barang akan menurun jika harga barang di Amerika menjadi mahal dikarenakan inflasi yang cukup tinggi. Harga yang naik akan menyebabkan menurunnya permintaan sedangkan harga yang turun akan menyebabkan naiknya permintaan, seperti yang ada dalam hukum dasar ekonomi.

Tingkat inflasi berdampak pada nilai tukar (*exchange rate*) karena fungsi rasio uang dalam daya beli adalah sebagai titik nilai tukar yang menggambarkan hukum nilai. Jika inflasi di suatu negara meningkat, maka mata uang nasional akan menurun, sedangkan jika inflasi di suatu negara menurun, maka mata uang nasional akan meningkat. Hal ini akan mengakibatkan suatu kondisi. Jika inflasi dalam negeri menyusut, maka daya beli akan berkurang, dimana hal ini menyebabkan kecenderungan untuk menjatuhkan nilai tukar mata uang dalam negeri.

2. Aktivitas Neraca Pembayaran

Nilai tukar secara langsung dipengaruhi oleh aktivitas neraca pembayaran. Neraca pembayaran yang aktif, dimana meningkatnya permintaan dari debitur asing, maka akan meningkatkan nilai tukar mata uang nasional. Sedangkan saldo pembayaran yang pasif, dimana debitur dalam negeri menjual semuanya menggunakan mata uang asing, maka akan menurunkan nilai tukar mata uang nasional. Dampak dari neraca pembayaran pada nilai tukar ditentukan oleh tingkat keterbukaan ekonomi. Contohnya yaitu kuota dalam perdagangan, efek dari tarif yang berubah, subsidi dari ekspor, impor yang dibatasi dan sebagainya.

3. Perbedaan Suku Bunga di Berbagai Negara

Harga dari uang yang digunakan dalam jangka waktu tertentu adalah penjelasan dari tingkat bunga. Arus modal internasional juga dipengaruhi oleh berubah-ubahnya tingkat suku bunga. Pada dasarnya, jika suku bunga naik, maka akan mendorong masuknya modal asing. Suku bunga juga dapat memberi pengaruh terhadap operasi pasar valuta asing. Hal ini dikarenakan ketika melakukan transaksi, bank akan melihat perbedaan suku bunga di pasar modal nasional dan global.

Jika suku bunga asing berada ditingkat rendah maka bank akan memilih pinjaman di pasar uang asing, sedangkan jika suku bunga asing memiliki tingkat yang tinggi maka bank akan memilih pinjaman di pasar uang nasional. Selain itu, permintaan mata uang nasional akan menjadi tanda terima kredit yang mahal jika nominal suku bunga di suatu negara naik. Pengusaha akan meningkatkan biaya produk mereka dalam hal peminjaman untuk menghasilkan tingginya harga barang dalam negeri. Hal tersebut mengakibatkan nilai mata uang dalam negeri terhadap suatu negara berkurang.

Kebijakan dari pemerintah dapat mempengaruhi keseimbangan nilai tukar. Kebijakan tersebut seperti, pemerintah yang berusaha menghindari penghambatan dari nilai tukar valuta asing dan perdagangan luar negeri, serta melakukan intervensi di pasar uang.

4. Ekspektasi

Ekspektasi nilai tukar pada masa depan merupakan faktor lain yang mempengaruhi nilai tukar valuta asing. Setiap berita yang berdampak di masa yang akan datang membuat pasar valuta asing bereaksi agresif. Contohnya, berita tentang pelonjakan inflasi di Amerika Serikat yang memungkinkan pedagang valuta asing menjual US\$ dikarenakan perkiraan nilai US\$ yang akan turun di masa yang akan datang. Hal tersebut secara otomatis akan menekan nilai tukar US\$ dalam pasar valuta asing.

3.2 Peramalan

Peramalan (*forecasting*) adalah proses untuk memprediksi hal apa yang akan terjadi dalam masa yang akan datang. Sedangkan ramalan merupakan suatu situasi kondisi yang diperkirakan akan terjadi pada masa yang akan datang. Sangat diperlukan data yang akurat di masa lalu untuk melakukan prediksi. Kegunaan peramalan dapat dilihat pada saat suatu pengambilan keputusan. Keputusan yang didasarkan pada pertimbangan apa yang akan terjadi adalah keputusan yang baik.

Baik tidaknya suatu hasil penelitian sangat ditentukan oleh ketetapan ramalan yang dibuat. Akan tetapi, ramalan selalu ada unsur kesalahannya, sehingga perlu diperhatikan untuk memperkecil kesalahan dari ramalan tersebut. Metode peramalan dibagi ke dalam dua kategori utama, yaitu metode kualitatif dan metode kuantitatif. Metode yang dilakukan apabila data masa lalu tidak ada yang menyebabkan peramalan tidak bisa dilakukan adalah metode kualitatif. Dalam metode tersebut, pendapat dari para ahli akan sangat dipertimbangkan dalam pengambilan keputusan berdasar hasil peramalan yang telah dilakukan. Namun, jika data masa lalu tersedia, peramalan menggunakan metode kuantitatif akan lebih efektif untuk digunakan. (Pujiati & dkk, 2003)

3.3 Jaringan Saraf Tiruan (JST)

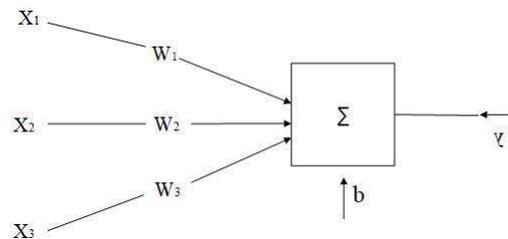
Jaringan saraf tiruan (Bahasa Inggris: *artificial neural network (ANN)*, atau juga disebut *simulated neural network (SNN)*, atau umumnya hanya disebut *neural network (NN)*), adalah jaringan dari sekelompok unit pemroses kecil yang dimodelkan berdasarkan sistem saraf manusia. JST merupakan sistem adaptif yang dapat mengubah strukturnya untuk memecahkan masalah berdasarkan informasi eksternal maupun internal yang mengalir melalui jaringan tersebut. Oleh karena sifatnya yang adaptif, JST juga sering disebut dengan jaringan adaptif.

Secara sederhana, JST adalah sebuah alat pemodelan data statistik non-linier. JST dapat digunakan untuk memodelkan hubungan yang kompleks antara input dan output untuk menemukan pola-pola pada data. Menurut suatu teorema yang disebut "teorema penaksiran universal", JST dengan minimal sebuah lapis tersembunyi dengan fungsi aktivasi non-linear dapat memodelkan seluruh fungsi terukur Boreal apapun dari suatu dimensi ke dimensi lainnya. (Wikipedia, 2017)

Pada jaringan syaraf tiruan, setiap *neuron* menggunakan fungsi aktivasi terhadap input-input yang diterimanya lalu setelahnya baru diteruskan ke *neuron* pada lapisan selanjutnya. Fungsi yang menghasilkan nilai yang menunjukkan tingkat aktif *neuron* disebut fungsi aktivasi $f(x)$. Terdapat tiga tipe dasar fungsi aktivasi yaitu fungsi linear

(*purelin*), fungsi *sigmoid biner (logsig)*, Fungsi *Sigmoid Bipolar (tansig)*.(Arifianty & dkk, 2017)

Pada **Gambar 3.1** ini menunjukkan struktur jaringan syaraf tiruan.



Gambar 3. 1Struktur Jaringan Saraf Tiruan

Dengan keterangan :

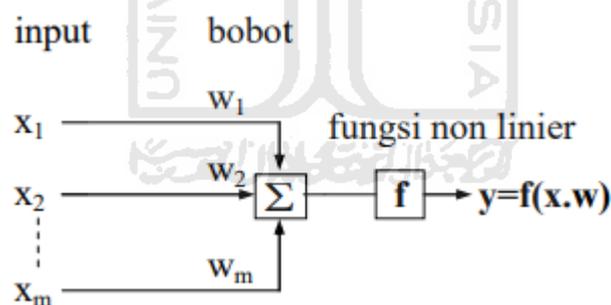
X = input data yang digunakan

W = Bobot Input

b = Nilai Bias

y = nilai *output layer*

Model matematis dari sebuah sel syaraf diperlihatkan dalam **Gambar 3.2**:



Gambar 3. 2Model Matematis Jaringan Saraf Tiruan

Jika dinyatakan dalam notasi matematika:

$$y = f(x_1w_1 + x_2w_2 + \dots + x_mw_m) \quad (3.1)$$

$$y = f(x.w) \quad (3.2)$$

3.4 *Extreme Learning Machine (ELM)*

Terdapat metode pembelajaran baru dari jaringan syaraf tiruan yang disebut *Extreme Learning Maching (ELM)*. ELM diperkenalkan oleh (Huang, Zhu, & Siew, 2004) yang merupakan metode pengembangan dari jaringan syaraf tiruan *feedforward* sederhana dengan menggunakan satu *hidden layer* atau biasa dikenal dengan

Single Hidden Layer Feedforward Neural Networks (SLFNs). Metode pembelajaran ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed*. Huang et al mengemukakan dua alasan mengapa JST feedforward mempunyai *learning speed* rendah, yaitu menggunakan *slow gradient based learning algorithm* untuk melakukan *training* dan semua parameter pada jaringan ditentukan secara *iterative* dengan menggunakan metode pembelajaran tersebut.

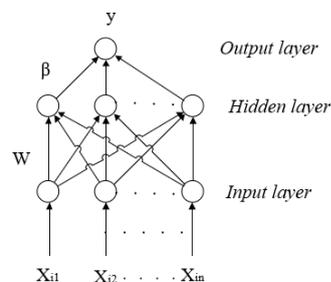
Pada ELM parameter-parameter seperti *input weight* dan *hidden bias* dipilih secara *random*, sehingga ELM memiliki *learning speed* yang cepat dan mampu menghasilkan *good generalization performances*.

ELM menggunakan arsitektur *single hidden layer feedforward* (Handika, 2016), arsitektur tersebut terbagi menjadi layer *input* dan layer *output*, dimana layer input berperan dalam menerima sinyal data input sedangkan layer output berfungsi sebagai media dalam memberikan hasil output.

Kelemahan ELM yaitu jumlah hidden nodes ditentukan dengan cara try and error, sehingga tidak bisa diketahui berapa jumlah hidden nodes yang tepat untuk mendapatkan hasil peramalan menggunakan metode ELM. (Handika, 2016) Kelebihan ELM yaitu cepat dalam proses pembelajaran atau memiliki *learning speed* yang baik. (Alfiyatin & dkk, 2019)

Dalam proses menggunakan metode ELM terdapat *rep* atau *repetitions* yang tertulis dalam *syntax ELM* yang ada dalam **Lampiran B.**, *rep* menunjukkan jumlah jaringan yang dilatih.

Struktur ELM ditunjukkan pada **Gambar 3. 2** (Giusti, Widodo, & Adinugroho, 2018)



Gambar 3. 3 Struktur ELM

Dengan keterangan :

y = nilai *output layer*

β = *Output Weight*

X = input data yang digunakan

W = BobotInput

n = Jumlah *input neuron*

Berikut model matematis dari ELM untuk N jumlah sampel yang berbeda (X_i, t_i):

$$X_i = [X_{i1}, X_{i2}, \dots, X_{in}]^T \in R^n \quad (3.4)$$

$$X_t = [X_{t1}, X_{t2}, \dots, X_{tn}]^T \in R^n \quad (3.5)$$

Standar SLFNs dengan jumlah *hidden nodes* sebanyak N dan fungsi aktivasi(x) dapat digambarkan secara matematis:

$$\sum_{i=1}^N \beta_i g_i(x_j) = \sum_{i=1}^N \beta_i g(W_i \cdot X_i + b_i) = 0_j \quad (3.6)$$

Dimana:

- $j = 1, 2, \dots, N$
- $w_i = (w_{i1}, w_{i2}, \dots, w_{in})^T$ merupakan vektor bobot yang menghubungkan *hidden node* ke- i dan *input nodes*
- $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{in})^T$ merupakan vektor bobot yang menghubungkan *hidden node* ke- i dan *output nodes*
- b_i merupakan *threshold* dari *hidden node* ke- i
- $w_i \cdot x_j$ merupakan *inner product* dari w_i dan x_j

Berikut adalah algoritma ELM:

- Menentukan fungsi aktivasi ($g(x)$) dan banyaknya *hidden* (\tilde{N}).
- Menentukan bobot *input* (w_i) secara acak.
- Menghitung bobot *output* (β_i) dengan persamaan:

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

dimana

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix} \quad (3.8)$$

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} \quad (3.9)$$

4. Melakukan peramalan dengan ELM berdasarkan bobot *input* dan bobot *output* yang didapatkan sebelumnya.

3.5 Data Training dan Data Testing

Data umumnya dibagi menjadi data *training* dan data *testing*. Data *Training* digunakan oleh algoritma klasifikasi (misalnya: *decision tree*, *bayesian*, *neural network*, SVM) untuk membentuk sebuah model *classifier*. Model ini merupakan representasi pengetahuan yang akan digunakan untuk prediksi kelas data baru yang belum pernah ada. Data *Training* digunakan untuk mengukur sejauh mana *classifier* berhasil melakukan klasifikasi dengan benar. Karena itu, data yang ada pada data *testing* seharusnya tidak boleh ada pada data *training* sehingga dapat diketahui apakah model *classifier* sudah “pintar” dalam melakukan klasifikasi. Proporsi antara data training dan data testing tidak mengikat tetapi agar variasi dalam model tidak terlalu besar maka disarankan data training lebih besar dibandingkan data testing (Paratu, 2003 dalam Estroatnowo 2016).

3.6 Data Training dan Data Testing

3.6.1 Mean Square Error (MSE)

Mean Square Error (MSE) adalah metode untuk mengevaluasi metode ramalan. Nilai *error* yang asli tidak dirata-ratakan sebagai ukuran besar kecilnya *error*, akibatnya penyimpangan dari peramalan yang sebenarnya besar karena kalau *error* dijumlahkan begitu saja *error* positif besar akan di hilangkan oleh *error* negatif yang besar. Untuk menghindari hal ini maka *error* perlu dijadikan angka mutlak atau dikuadratkan kemudian baru dirata-ratakan (Subagyo, 1986).

$$MSE = \frac{\sum_{t=1}^n [x_t - \hat{x}_t]^2}{n} \quad (4.0)$$

Dimana:

x_t : Data aktual pada periode t

\hat{x}_t : Data peramalan pada periode t

n : Jumlah data

BAB IV METODOLOGI PENELITIAN

4.1 Populasi dan Sampel

Populasi yang ada adalah data nilai tukar mata uang tahun 2009 hingga tahun 2019, sedangkan sampel yang digunakan pada penelitian ini adalah data nilai tukar mata uang Rupiah terhadap Dollar Amerika mulai 01 Januari 2009 hingga 28 Juni 2019.

4.2 Sumber Data

Data dalam penelitian ini menggunakan data yang bersumber dari website resmi Bank Indonesia (BI) www.bi.go.id

4.3 Variabel Penelitian

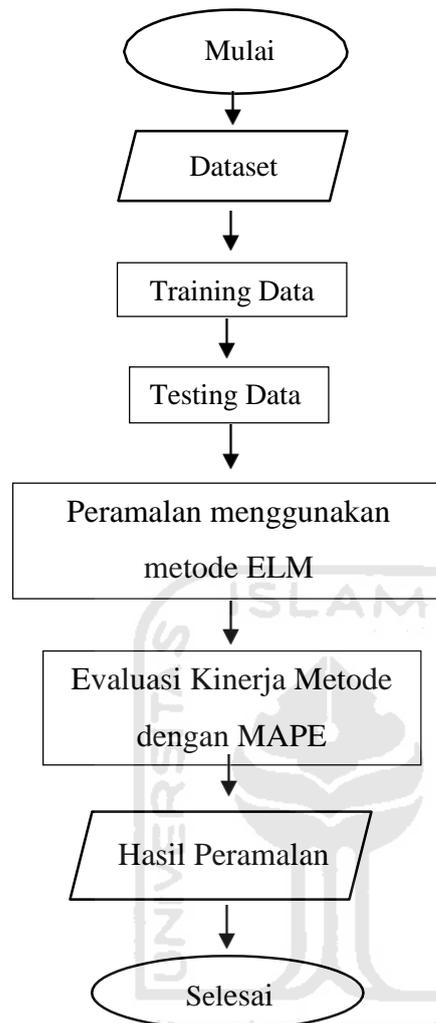
Penelitian ini hanya memiliki satu macam variable, yaitu sebagai berikut:

Tabel 4. 1 Variabel Penelitian

Nama Variabel	Definisi
Kurs Jual	Kurs jual merupakan acuan dalam penukaran rupiah ke uang asing. Variabel ini dinyatakan dalam rupiah.

4.4 Metode Analisis Data

Metode analisis yang digunakan dalam penelitian ini adalah *Extreme Learning Machine* (ELM). Langkah awal yang dilakukan dalam penelitian ini adalah analisis deskriptif pada setiap data yang digunakan dalam analisis dan disusul langkah-langkah selanjutnya sebagai berikut:



Gambar 4. 1 Flowchart Penelitian

Berikut langkah-langkah penelitian dengan menggunakan metode analisis ELM yaitu:

1. Melakukan input data nilai kurs jual dan kurs beli dari bulan Januari tahun 2009 sampai dengan bulan Juni 2019 ke dalam *software* R
2. Melakukan proses *training* pada data kursjual
3. Melakukan proses *testing* pada data kurs jual untuk menentukan peramalan kurs bulan Juli 2019
4. Peramalan kurs bulan Juli 2019
5. Melakukan evaluasi kinerja metode peramalan dengan MAPE
6. Menyajikan dan membahas *output* hasil peramalan
7. Kesimpulan

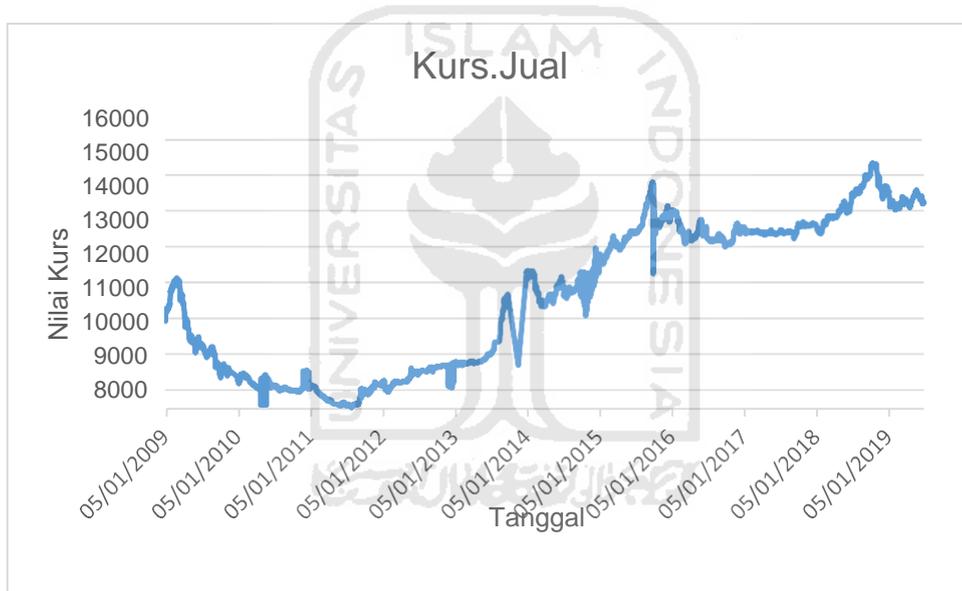
BAB V

HASIL DAN PEMBAHASAN

Pada bab ini akan menjelaskan hasil yang diperoleh berdasarkan studi kasus dan teori-teori yang telah dijelaskan pada bab-bab sebelumnya. Analisis yang digunakan dalam penelitian ini adalah, analisis deskriptif, analisis metode *Extreme Learning Machine*. Dengan menggunakan *software R.3.4.2*.

5.1 Analisis Deskriptif

Pada analisis deskriptif ini menggunakan diagram untuk menggambarkan keadaan.



Gambar 5.1 Pergerakan Kurs Jual dari Januari 2009- Juni 2019

Pada **Gambar 5.1** menunjukkan bahwa data kurs jual mengalami fluktuasi. Dapat dilihat pada pergerakan kurs jual tahun dari tahun 2015 mengalami kenaikan sampai pada tahun 2016 mencapai Rp 14.000 atau bisa dikatakan bahwa nilai Rupiah terhadap USD lemah. Hal tersebut dipengaruhi oleh perjalanan rupiah sepanjang 2016 mendapatkan sentimen dari pemulihan ekonomi dunia yang masih lemah dan ketidakpastian yang ditimbulkan oleh, antara lain keluarnya Inggris dari Uni Eropa (Brexit) dan kenaikan suku bunga Bank

Sentral AS. The Fed akhirnya menaikkan suku bunga 25 basis poin di bulan Desember (BeritaSatu, 2016).

Setelah analisis deskriptif, proses berikutnya adalah analisis dengan *Extrem Learning Machine* (ELM).

5. 2 Peramalan *Extreme Learning Machine*

5. 2 .1 Mengubah Data Menjadi *Time Series*

Data yang diperoleh akan diubah menjadi data runtun waktu atau *time series*. Karena data runtun waktu merupakan data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu, maka dalam penelitian ini data yang digunakan adalah data kurs jual Rupiah terhadap USD dari Januari 2009 sampai Juni 2019. Data dapat dilihat dalam lampiran 2.

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

Dalam proses peramalan menggunakan metode ELM yang dilakukan pertama kali yaitu membagi data menjadi dua bagian yaitu data *training* dan *testing*. Dalam metode ini jika semakin banyak data *training* yang digunakan maka semakin baik prediksi yang dihasilkan dengan melihat nilai *error* yang kecil karena metode ELM merupakan metode pelatihan. (Giusti, Agus dan Sigit. 2018).

Proses *training* dan *testing* mutlak diperlukan pada proses peramalan dengan ELM. Proses *training* untuk mengembangkan model dari ELM, sedangkan *testing* digunakan untuk mengevaluasi kemampuan ELM sebagai *forecasting tool*. Oleh karena itu data dibagi menjadi duayaitu data *training* dan *testing*.

Pembagian data *training* dan *testing* pada kurs jual dan kurs beli yaitu:

Tabel 5. 1 Pembagian Data *Training* dan *Testing*

<i>Training</i>	<i>Testing</i>
75% (1923 data)	25% (593 data)
80% (2006 data)	20 % (510 data)
90 % (2260 data)	10 % (256 data)

Pembagian data pada **Tabel 5. 1** menggunakan 3 skenario. Hal tersebut dilakukan untuk mendapatkan gambaran dari hasil *training* dan *testing* yang lebih optimal, karena sampai saat ini belum terdapat referensi yang menyatakan aturan pembagian data *training* dan *testing*.

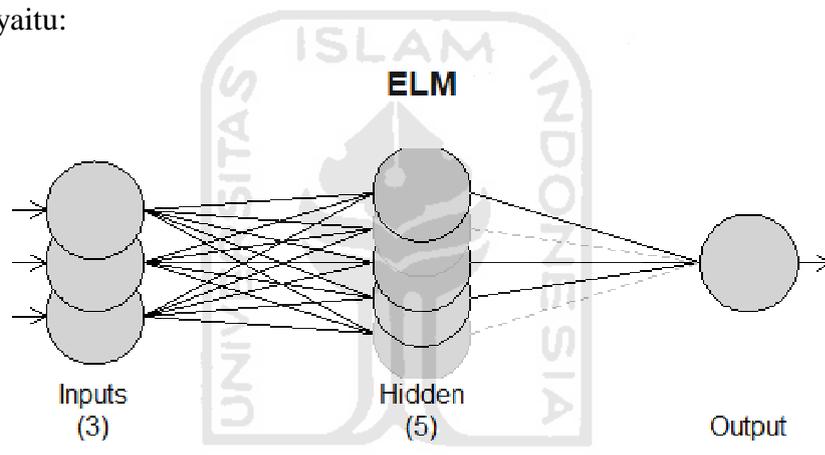
5. 2 .3 TrainingData

Sebelum digunakan sebagai *tool* peramalan, ELM harus melalui proses *training* terlebih dahulu *output* dengan tingkat kesalahan yang rendah.

5. 2. 3. 1 Training 75%

a. Hidden Layer 5 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

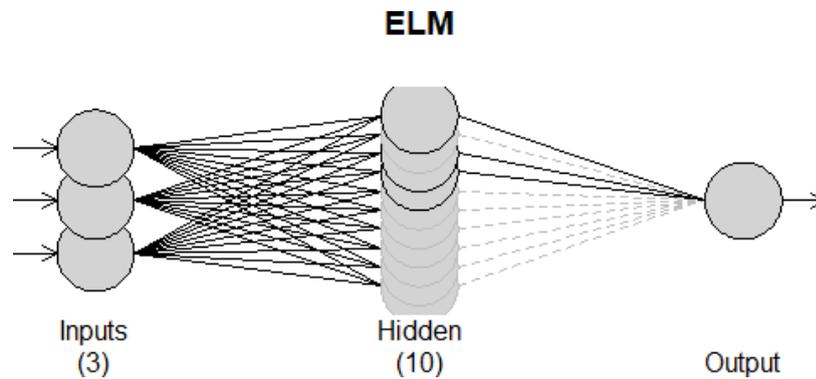


Gambar 5. 2 Arsitektur jaringan *hidden layer* 5 pada data *training* 75%

Pada **Gambar 5. 2** dapat dilihat pada bagian *Hidden (5)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 5, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* yang mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

b. Hidden Layer 10 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

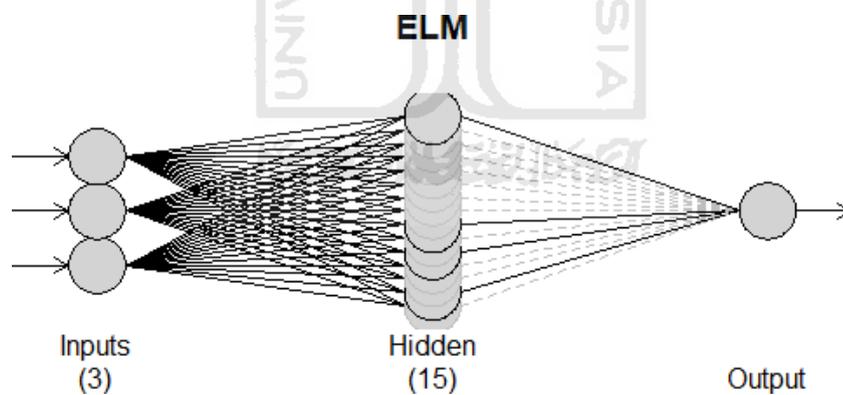


Gambar 5. 3 Arsitektur jaringan *hidden layer* 10 pada data *training* 75%

Pada **Gambar 5. 3** dapat dilihat pada bagian *Hidden (10)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 10, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

c. Hidden Layer 15 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



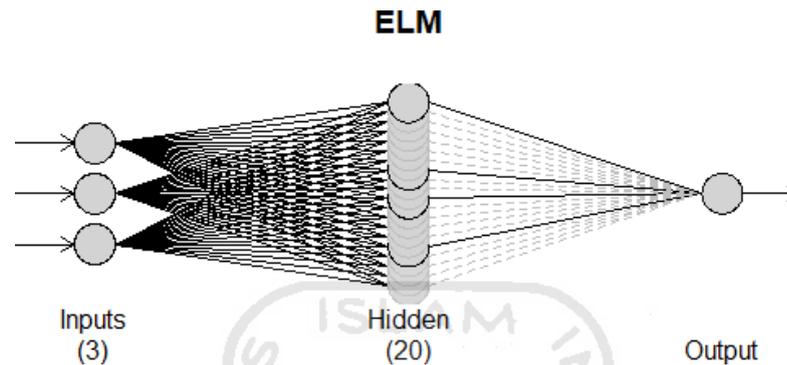
Gambar 5. 4 Arsitektur jaringan *hidden layer* 15 pada data *training* 75%

Pada **Gambar 5. 4** dapat dilihat pada bagian *Hidden (15)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 15, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi

terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

d. Hidden Layer 20 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



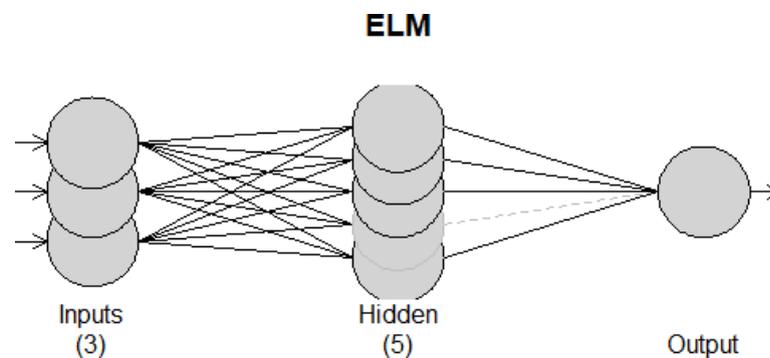
Gambar 5. 5 Arsitektur jaringan *hidden layer* 20 pada data *training* 75%

Pada **Gambar 5. 5** dapat dilihat pada bagian *Hidden (20)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 20, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

5. 2. 3. 2 Training 80%

a. Hidden Layer 5 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

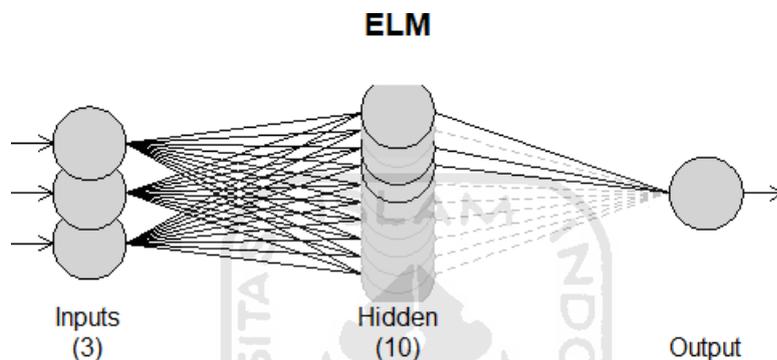


Gambar 5. 6 Arsitektur jaringan *hidden layer* 5 pada data *training* 80%

Pada **Gambar 5. 6** dapat dilihat pada bagian *Hidden (5)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 5, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

b. Hidden Layer 10 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

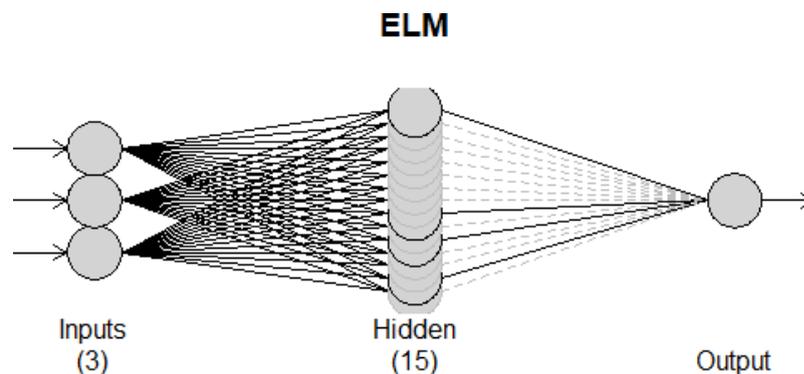


Gambar 5. 7 Arsitektur jaringan *hidden layer* 10 pada data *training* 80%

Pada **Gambar 5. 7** dapat dilihat pada bagian *Hidden (10)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 10, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi bahwa terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

c. Hidden Layer 15 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

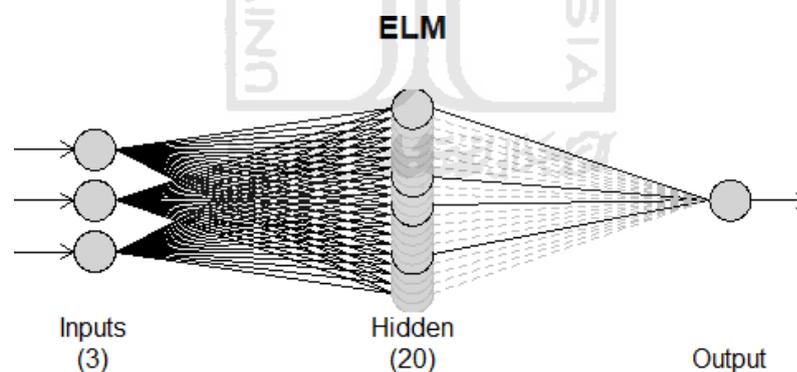


Gambar 5. 8 Arsitektur jaringan *hidden layer* 15 pada data *training* 80%

Pada **Gambar 5. 8** dapat dilihat pada bagian *Hidden (15)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 15, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

d. Hidden Layer 20 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



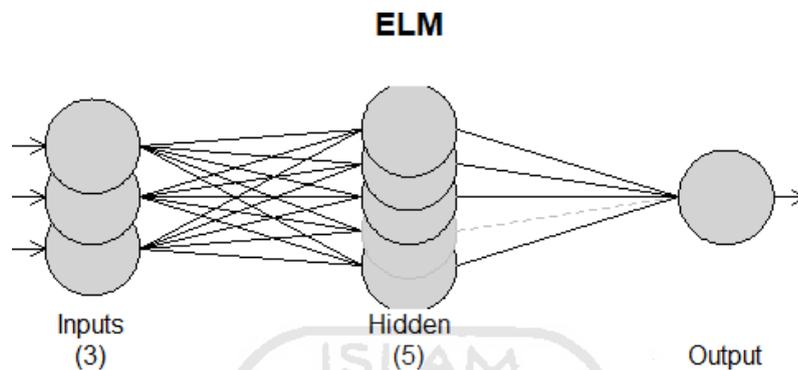
Gambar 5. 9 Arsitektur jaringan *hidden layer* 20 pada data *training* 80%

Pada **Gambar 5. 9** dapat dilihat pada bagian *Hidden (20)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 20, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

5. 2. 3. 3 Training 90%

a. Hidden Layer 5 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

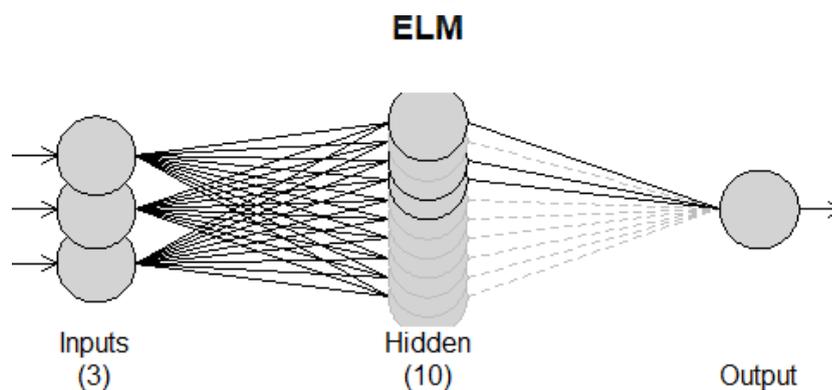


Gambar 5. 10 Arsitektur jaringan *hidden layer* 5 pada data *training* 90%

Pada **Gambar 5. 10** dapat dilihat pada bagian *Hidden (5)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 5, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

b. Hidden Layer 10 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

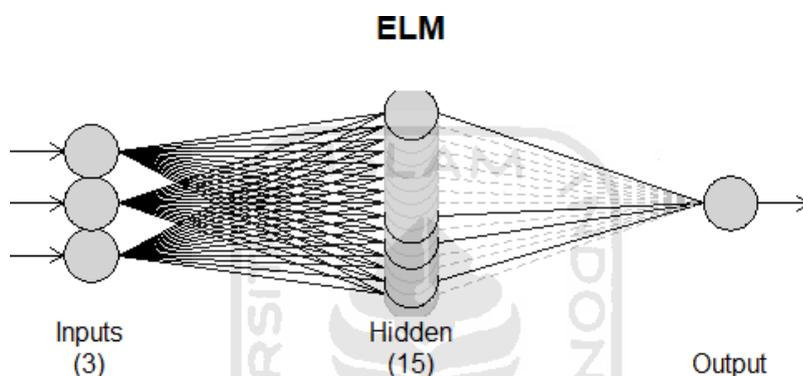


Gambar 5. 11 Arsitektur jaringan *hidden layer* 10 pada data *training* 90%

Pada **Gambar 5. 11** dapat dilihat pada bagian *Hidden (10)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 10, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

c. Hidden Layer 15 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

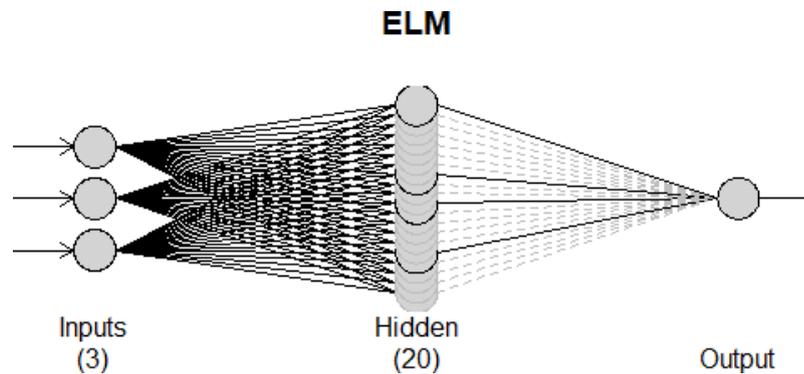


Gambar 5. 12 Arsitektur jaringan *hidden layer* 15 pada data *training* 90%

Pada **Gambar 5. 12** dapat dilihat pada bagian *Hidden (15)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 15, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi bahwa terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

d. Hidden Layer 20 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



Gambar 5. 13 Arsitektur jaringan *hidden layer* 20 pada data *training* 90%

Pada **Gambar 5. 13** dapat dilihat pada bagian *Hidden (20)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 20, lalu pada *node input* terdapat 3 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 3 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

5. 2. 3. 4 Output Training Data

Output dari proses *training* ELM diukur dengan *Mean Square Error* (MSE). Didapatkan hasil sebagai berikut:

Tabel 5. 2 Nilai MSE *training* 75%

<i>Repetitions</i>	<i>Hidden layer</i>			
	5	10	15	20
5	25687.03	25318.79	25653.33	24662.98
10	25104.20	24983.36	25059.17	24934.33
15	25488.70	25033.79	24800.80	24998.60
20	25276.22	24928.65	25129.04	24972.20

Pada **Tabel 5. 2** menunjukkan nilai MSE dengan data *training* sebesar 75% atau 1923 data. Dari tabel tersebut dapat dilihat bahwa MSE terkecil ditunjukkan pada *hidden layer* 20 dengan kombinasi *rep* 5 yaitu sebesar 24662.98.

Tabel 5. 3 Nilai MSE *training* 80%

<i>Repetitions</i>	<i>Hidden layer</i>			
	5	10	15	20
5	24956.84	23579.80	25021.67	23833.04
10	25066.38	23573.83	24120.87	24179.42
15	25655.96	23920.96	24083.82	24333.59
20	25410.37	23931.03	24160.01	24144.45

Pada **Tabel 5. 3** menunjukkan nilai MSE dengan data *training* sebesar 80% atau 2006 data. Dari tabel tersebut dapat dilihat bahwa MSE terkecil ditunjukkan pada *hidden layer* 10 dengan kombinasi *rep* 10 yaitu sebesar 23573.83.

Tabel 5. 4 Nilai MSE *training* 90%

<i>Repetitions</i>	<i>Hidden layer</i>			
	5	10	15	20
5	23461.33	21671.51	22308.37	21524.07
10	22633.72	21178.69	21363.97	21362.32
15	22596.72	21664.58	21238.46	21608.56
20	22354.46	21349.97	21675.12	21733.38

Pada **Tabel 5. 4** menunjukkan nilai MSE dengan data *training* sebesar 90% atau 2260 data. Dari tabel tersebut dapat dilihat bahwa MSE terkecil ditunjukkan pada *hidden layer* 10 dengan kombinasi *rep* 10 yaitu sebesar 21178.69.

Dari ketiga tabel tersebut dapat disimpulkan sebagai berikut:

Tabel 5. 5 Nilai MSE terkecil

<i>Training Data</i>	MSE terkecil	<i>Hidden layer dan repetitions</i>
75%	24662.98	<i>Hidden layer</i> 20 dengan <i>rep</i> 5
80%	23579.88	<i>Hidden layer</i> 10 dengan <i>rep</i> 10
90%	21178.69	<i>Hidden layer</i> 10 dengan <i>rep</i> 10

Dari **Tabel 5. 5** menunjukkan nilai MSE terkecil dari masing-masing *training* data. Dapat dilihat bahwa diantara ketiga nilai MSE tersebut yang terbaik adalah

nilai MSE dari *training* data 90% yaitu sebesar 21178.69 dengan *hidden layer* 10 dan kombinasi *rep* 10.

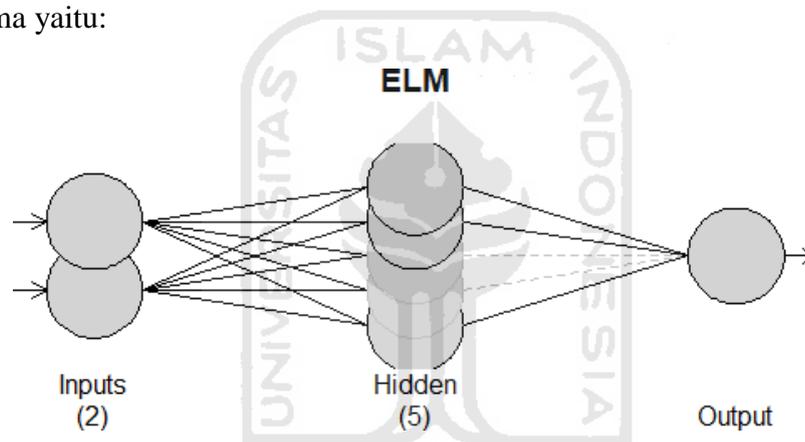
5.2.4 Testing Data

Berdasarkan *output* yang didapat dari proses *training*, maka tahap selanjutnya adalah melakukan peramalan dengan ELM (proses *testing*). Hasil optimal yang didapat pada proses *testing* ini akan digunakan untuk peramalan.

5.2.4.1 Testing 25%

a. Hidden Layer 5 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

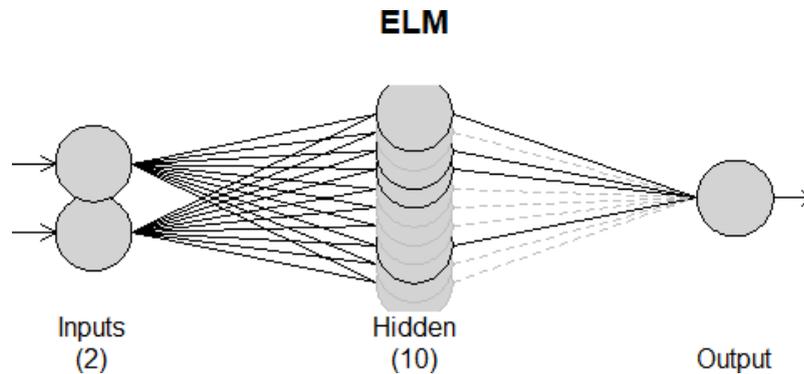


Gambar 5. 14 Arsitektur jaringan *hidden layer* 5 pada data *testing* 25%

Pada **Gambar 5. 14** dapat dilihat pada bagian *Hidden (5)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 5, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

b. Hidden Layer 10 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

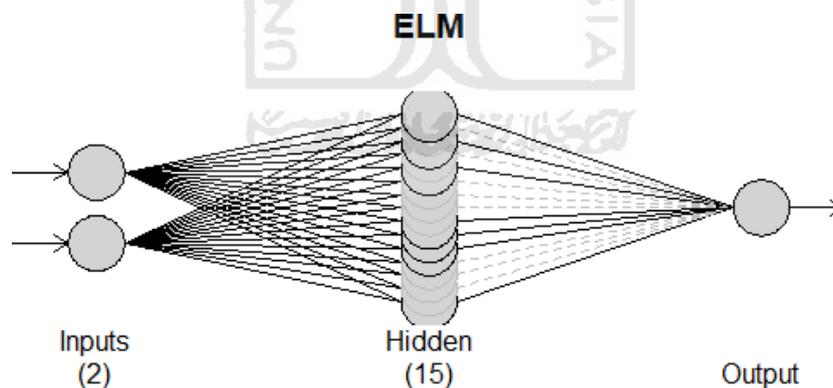


Gambar 5. 15 Arsitektur jaringan *hidden layer* 10 pada data *testing* 25%

Pada **Gambar 5. 15** dapat dilihat pada bagian *Hidden (10)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 10, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

c. Hidden Layer 15 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



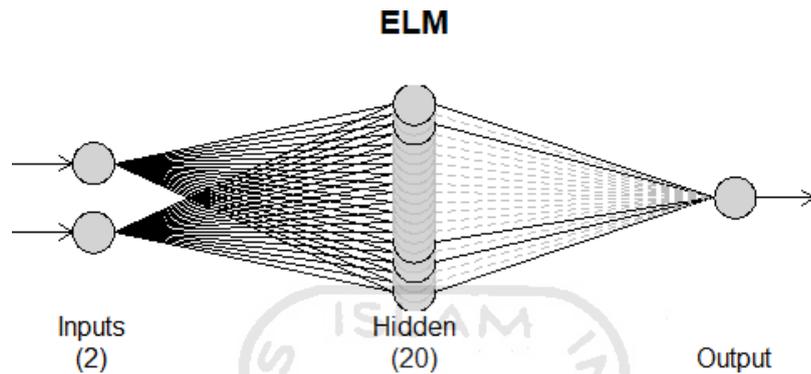
Gambar 5. 16 Arsitektur jaringan *hidden layer* 15 pada data *testing* 25%

Pada **Gambar 5. 16** dapat dilihat pada bagian *Hidden (15)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 15, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi

terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

d. Hidden Layer 20 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



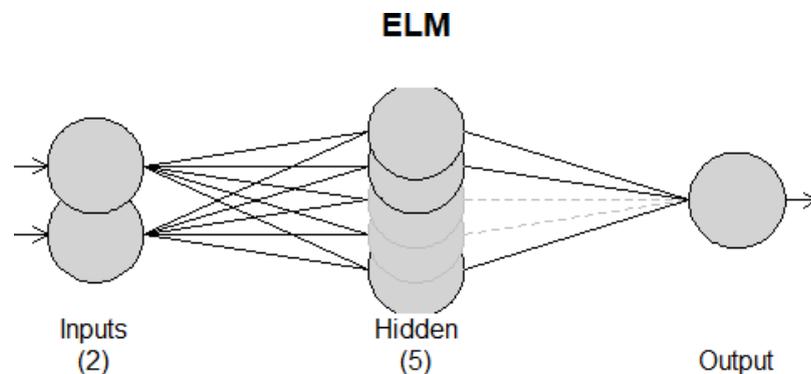
Gambar 5. 17 Arsitektur jaringan *hidden layer* 20 pada data *testing* 25%

Pada **Gambar 5. 17** dapat dilihat pada bagian *Hidden (20)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 20, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

5. 2. 4. 2 Testing 20%

a. Hidden Layer 5 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

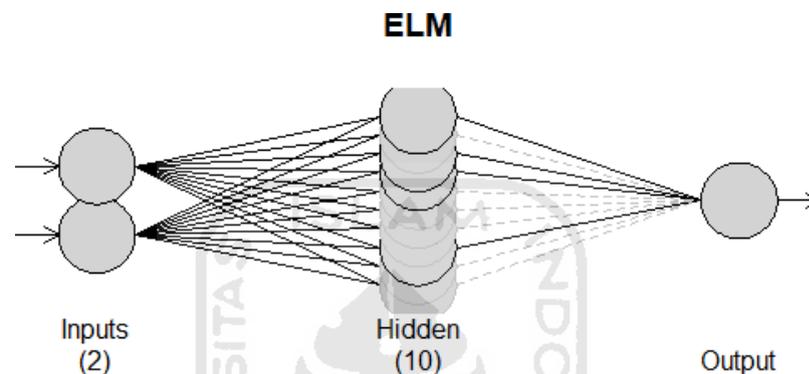


Gambar 5. 18 Arsitektur jaringan *hidden layer* 5 pada data *testing* 20%

Pada **Gambar 5. 18** dapat dilihat pada bagian *Hidden (5)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 5, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

b. Hidden Layer 10 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

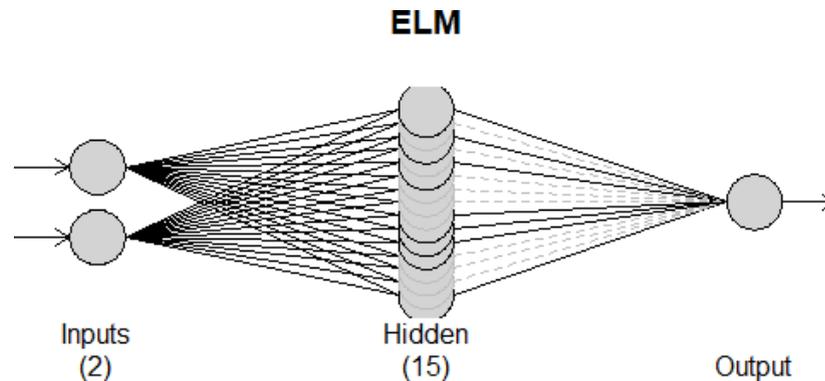


Gambar 5. 19 Arsitektur jaringan *hidden layer* 10 pada data *testing* 20%

Pada **Gambar 5. 19** dapat dilihat pada bagian *Hidden (10)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 10, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

c. Hidden Layer 15 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

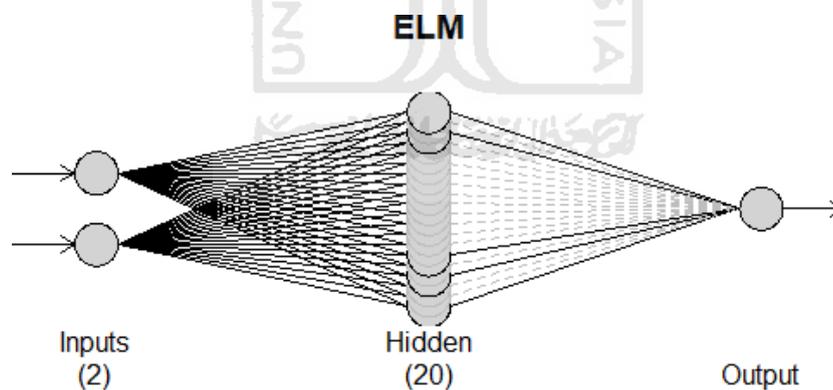


Gambar 5. 20 Arsitektur jaringan *hidden layer* 15 pada data *testing* 20%

Pada **Gambar 5. 20** dapat dilihat pada bagian *Hidden (15)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 15, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

d. Hidden Layer 20 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



Gambar 5. 21 Arsitektur jaringan *hidden layer* 20 pada data *testing* 20%

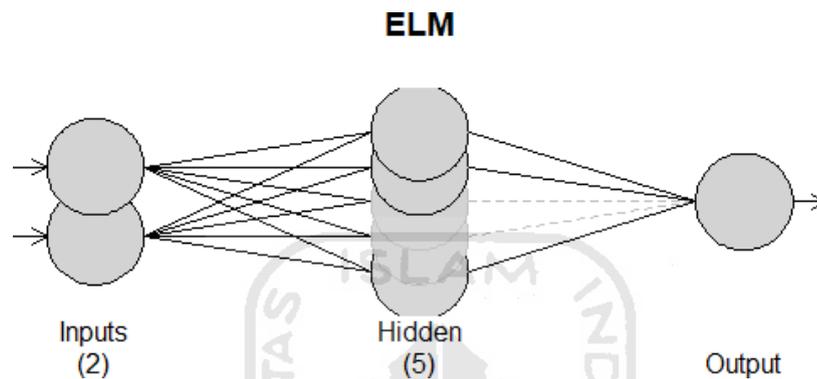
Pada **Gambar 5. 21** dapat dilihat pada bagian *Hidden (20)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 20, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi

terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

5. 2. 4. 3 *Testing 10%*

a. **Hidden Layer 5 Dengan Kombinasi Rep 5, 10, 15, dan 20**

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

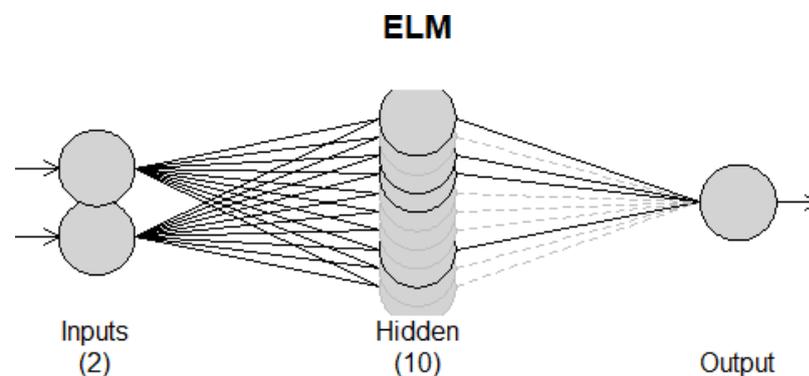


Gambar 5. 22 Arsitektur jaringan *hidden layer 5* pada data *testing 10%*

Pada **Gambar 5. 22** dapat dilihat pada bagian *Hidden (5)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 5, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

b. **Hidden Layer 10 Dengan Kombinasi Rep 5, 10, 15, dan 20**

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

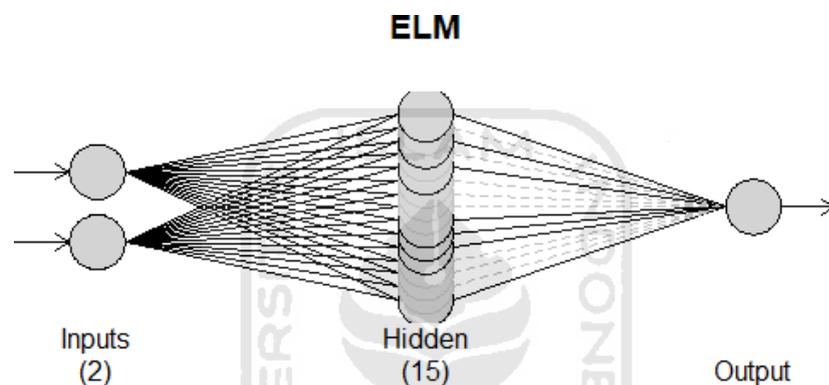


Gambar 5. 23 Arsitektur jaringan *hidden layer 10* pada data *testing 10%*

Pada **Gambar 5. 23** dapat dilihat pada bagian *Hidden (10)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 10, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

c. Hidden Layer 15 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:

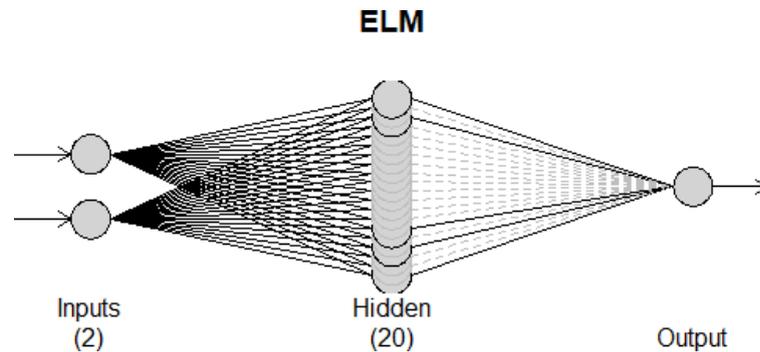


Gambar 5. 24 Arsitektur jaringan *hidden layer* 15 pada data *testing* 10%

Pada **Gambar 5. 24** dapat dilihat pada bagian *Hidden (15)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 15, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

d. Hidden Layer 20 Dengan Kombinasi Rep 5, 10, 15, dan 20

Hasil *running* untuk rep 5, 10, 15, dan 20 menghasilkan jaringan arsitektur yang sama yaitu:



Gambar 5. 25 Arsitektur jaringan *hidden layer* 10 pada data *testing* 10%

Pada **Gambar 5. 25** dapat dilihat pada bagian *Hidden (20)* yang menunjukkan bahwa jaringan memiliki *hidden layer* sebanyak 20, lalu pada *node input* terdapat 2 *node* yang berasal dari *lag* dan memiliki asumsi terdapat 2 *node input* mewakili tanggal, sedangkan 1 *node* sebagai *output node* adalah hasil dari prediksi.

5. 2. 4. 4 Output Testing Data

Output dari proses *training* ELM diukur dengan *Mean Square Error* (MSE). Didapatkan hasil sebagai berikut:

Tabel 5. 6 Nilai MSE *testing* 25%

<i>Repetitions</i>	<i>Hidden layer</i>			
	5	10	15	20
5	2374.51	2352.56	2334.11	2336.34
10	2386.19	2332.96	2353.46	2326.44
15	2354.33	2331.49	2334.24	2319.92
20	2406.69	2326.20	2337.84	2330.19

Pada **Tabel 5. 6** menunjukkan nilai MSE dengan data *testing* sebesar 25% atau 593 data. Dari tabel tersebut dapat dilihat bahwa MSE terkecil ditunjukkan pada *hidden layer* 20 dengan kombinasi *rep* 15 yaitu sebesar 2319.92.

Tabel 5. 7 Nilai MSE *testing*20%

<i>Repetitions</i>	<i>Hidden layer</i>			
5	2370.29	2346.95	2376.16	2347.59
10	2568.05	2379.17	2360.74	2343.90
15	2360.26	2354.22	2344.51	2361.07
20	2372.41	2351.73	2351.41	2385.04

Pada **Tabel 5. 7** menunjukkan nilai MSE dengan data *testing* sebesar 20% atau 510 data. Dari tabel tersebut dapat dilihat bahwa MSE terkecil ditunjukkan pada *hidden layer* 20 dengan kombinasi *rep* 10 yaitu sebesar 2343.90.

Tabel 5. 8 Nilai MSE *testing*10%

<i>Repetitions</i>	<i>Hidden layer</i>			
5	4048.88	3726.23	3745.68	3733.11
10	3672.80	3746.23	3740.03	3669.05
15	3816.29	3738.54	3787.87	3721.82
20	3847.73	3713.77	3758.88	3764.26

Pada **Tabel 5. 8** menunjukkan nilai MSE dengan data *testing* sebesar 10% atau 256 data. Dari tabel tersebut dapat dilihat bahwa MSE terkecil ditunjukkan pada *hidden layer* 20 dengan kombinasi *rep* 10 yaitu sebesar 3669.05.

Dari ketiga tabel tersebut dapat disimpulkan sebagai berikut:

Tabel 5. 9 Nilai MSE terkecil

<i>TestingData</i>	MSE terkecil	<i>Hidden layer dan repetitions</i>
25%	2319.92	<i>Hidden layer</i> 20 dengan <i>rep</i> 15
20%	2343.90	<i>Hidden layer</i> 20 dengan <i>rep</i> 10
10%	3669.05	<i>Hidden layer</i> 20 dengan <i>rep</i> 10

Dari **Tabel 5. 9** menunjukkan nilai MSE terkecil dari masing-masing *testingdata*. Dapat dilihat bahwa diantara ketiga nilai MSE tersebut yang terbaik adalah nilai MSE dari *testingdata* 25% yaitu sebesar 2319.92 dengan *hidden layer* 20 dan kombinasi *rep* 15. Hasil tersebut selanjutnya digunakan untuk melakukan analisis hasil peramalan.

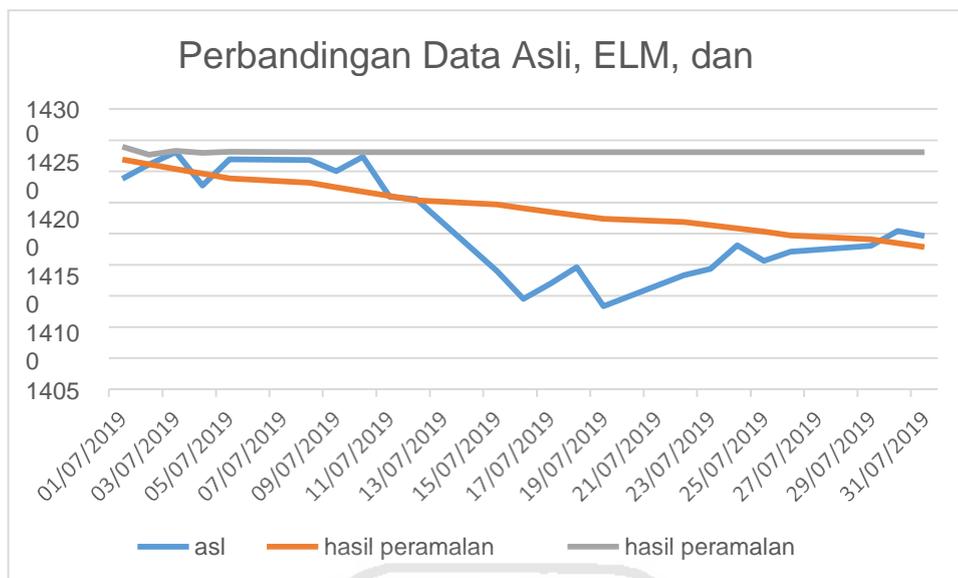
5. 2 .5 Analisis Hasil Proses Peramalan *Extreme Learning Machine*

Setelah melalui berbagai tahapan, berdasarkan evaluasi kinerja peramalan didapatkan nilai MSE terkecil terdapat dalam *testing* data 25% serta *hidden layer* 20 dan kombinasi *rep* 15 dengan nilai MAPE sebesar 0.3475. Berikut hasil peramalannya:

Tabel 5. 10 Perbandingan hasil peramalan dengan data asli

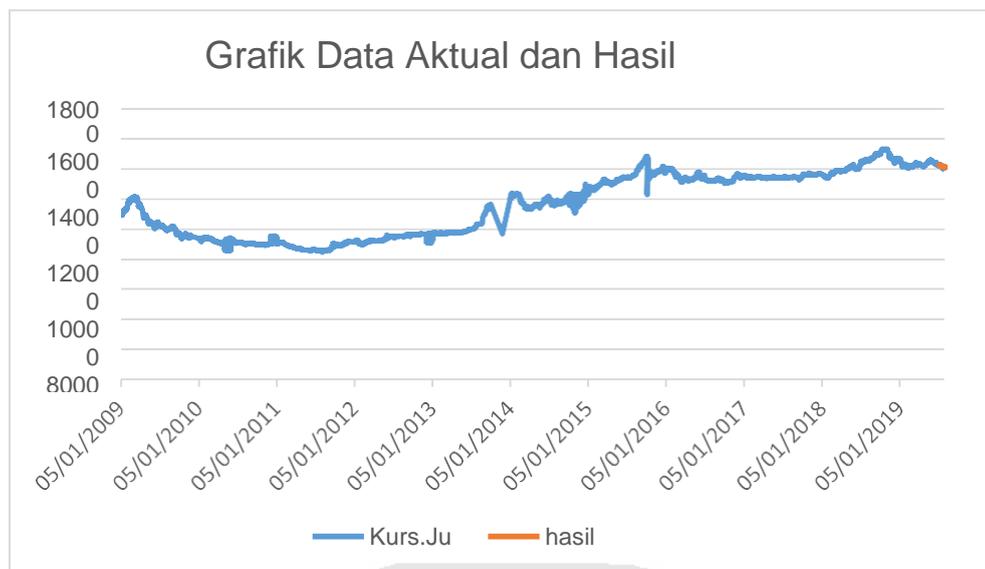
Tanggal	Data asli	Hasil peramalan
01/07/2019	14188	14219
02/07/2019	14211	14211
03/07/2019	14231	14204
04/07/2019	14177	14196
05/07/2019	14219	14189
08/07/2019	14218	14182
09/07/2019	14200	14175
10/07/2019	14223	14167
11/07/2019	14159	14160
12/07/2019	14155	14154
15/07/2019	14040	14147
16/07/2019	13995	14141
17/07/2019	14019	14135
18/07/2019	14046	14129
19/07/2019	13983	14124
22/07/2019	14033	14119
23/07/2019	14043	14113
24/07/2019	14081	14109
25/07/2019	14056	14103
26/07/2019	14071	14097
29/07/2019	14080	14091
30/07/2019	14104	14085
31/07/2019	14096	14079

Hasil peramalan kurs jual bulan juli tahun 2019 disajikan dalam bentuk **Gambar 5. 26**, berikut adalah plot perbandingan antara data aktual dan hasil peramalan:



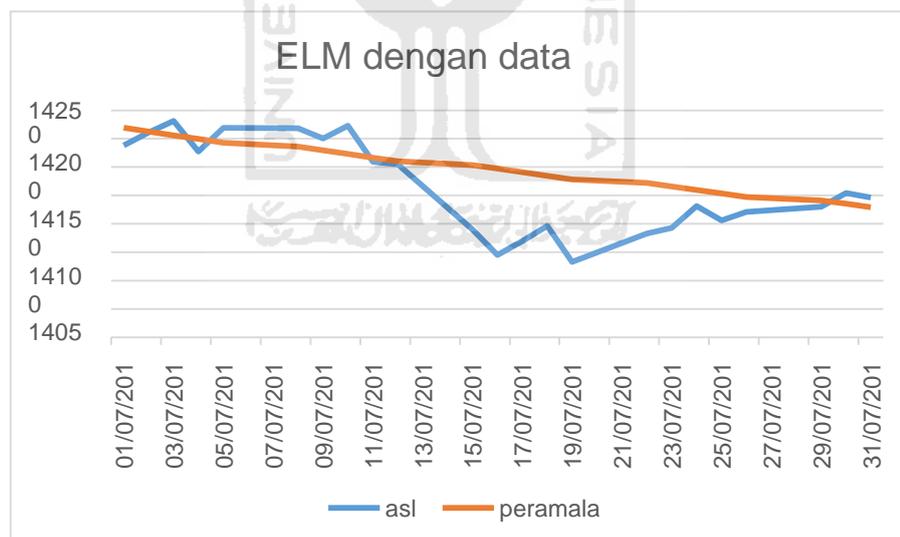
Gambar 5.26 Perbandingan data asli dan hasil peramalan kurs jual

Gambar 5.26 merupakan grafik perbandingan antara data asli dengan data hasil peramalan pada kurs jual menggunakan metode ELM. Sumbu x merupakan tanggal sejak 1 Juli 2019 sampai dengan 31 Juli 2019, serta sumbu y merupakan nilai kurs jual dalam rupiah. Data aktual kurs jual ditunjukkan grafik warna biru, untuk grafik berwarna oranye menunjukkan hasil ramalan nilai kurs jual dengan metode ELM, dan grafik warna abu-abu menunjukkan hasil peramalan nilai kurs jual menggunakan metode ARIMA. Dapat dilihat pada **Gambar 5.26** bahwa grafik hasil peramalan kurs jual bulan Juli tahun 2019 menggunakan ELM lebih bagus jika dibandingkan dengan hasil peramalan kurs jual bulan Juli tahun 2019 menggunakan ARIMA yang ditunjukkan pada. Nilai MAPE hasil peramalan menggunakan ARIMA sebesar 0.831172, sedangkan nilai MAPE hasil peramalan menggunakan ELM sebesar 0.3475. Oleh karena itu, metode ELM lebih cocok digunakan dalam memprediksi kurs jual bulan Juli tahun 2019.



Gambar 5. 27 Grafik hasil peramalan kurs jual

Terlihat pada **Gambar 5. 27**, data aktual ditunjukkan oleh grafik warna biru, sedangkan grafik berwarna oren menunjukkan data hasil peramalan kurs jual bulan Juli tahun 2019. Hasil peramalan kurs jual memiliki rata-rata sebesar 14145.



Gambar 5. 28 Grafik hasil peramalan ELM dengan outlier

Dari grafik diatas dapat dibandingkan dengan grafik pada **Gambar 5. 29** bahwa kedua grafik tidak berbeda jauh. Hasil MAPE hasil peramalan dengan adanya data outlier sebesar 0.3572, sedangkan hasil MAPE hasil peramalan tanpa adanya data outlier sebesar 0.3475. Hal tersebut menunjukkan bahwa tidak ada pengaruh outlier dalam peramalan.

BAB VI

PENUTUP

6.1 Kesimpulan

Berdasarkan pembahasan maka diperoleh beberapa kesimpulan bahwa dari hasil analisis yang telah dilakukan terdapat beberapa informasi yaitu:

1. Pada umumnya nilai tukar kurs dari bulan Januari tahun 2009 sampai dengan bulan Juni tahun 2019 mengalami fluktuasi.
2. Dari hasil evaluasi kinerja peramalan didapatkan nilai MSE terkecil yaitu sebesar 2319.92, yang berarti bahwa kombinasi terbaik terdapat dalam data *testing* 10% dengan *hidden layer* 20 dan kombinasi *rep* 15.

6.2 Saran

Berikut adalah saran dan kesimpulannya yang didapatkan berdasarkan hasil penelitian:

1. Penelitian ini mengkaji metode Extreme Machine Learning (ELM) yang diaplikasikan ke dalam bidang ilmu ekonomi. Penelitian mengenai metode-metode dalam analisis peramalan masih dapat dikembangkan lagi terutama pada bidang ilmu lain mengingat cakupan analisis peramalan yang sangat luas.
2. Diharapkan hasil analisis ini digunakan sebagai bahan pertimbangan dalam menentukan strategi dan kebijakan kedepan.
3. Untuk penelitian berikutnya dapat melakukan analisis prediksi menggunakan metode yang berbeda.

Daftar Pustaka

- Agustina, I. D. (2010). PENERAPAN METODE EXTREME LEARNING MACHINE ELM UNTUK PERAMALAN PERMINTAAN.
- Alfiyatin, A. N., & dkk. (2019). Penerapan Extreme Learning Machine (ELM) untuk Peramalan Laju Inflasi di Indonesia.
- Alkhatib. (2013). Stock Price Prediction Using k-Nearest Neighbor (kNN) Algorithm.
- Aprilliani. (2015). Dampak Lemahnya Nilai Tukar Rupiah Terhadap Dolar AS bagi Perekonomian Indonesia.
- Arifianty, A., & dkk. (2017). Peramalan Indeks Harga Saham Gabungan (IHSG) dengan Metode Extreme Learning Machine (ELM).
- Ayustina Giusti, A. W. (2017). Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta.
- Bertalya. (2009). *Konsep Data Mining*. Depok: Universitas Gunadharma.
- Estoatnowo, D. (2016). Klasifikasi Status Kelulusan Mahasiswa Menggunakan Metode CHAID dan Algoritma C4.5 (Studi Kasus : Mahasiswa Jurusan Statistika Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia).
- Fikriya, Z. A., & dkk. (2017). Implementasi Extreme Learning Machine untuk.
- Handika, P. S. (2016). *Perbandingan Metode Extreme Learning Machine dan Particle Swarm Optimization Extreme Learning Machine untuk Peramalan Jumlah Penjualan Barang*.
- Huang, G. B. (2004). *Extreme Learning Machine :Theory and applications. Neurocomputing*. Retrieved from <http://www.ntu.edu.sg/home/egbhuang>
- Iskandar, S. (2004). Sistem dan Kebijakan Nilai Tukar.
- Lestari, S. (2015). *Penurunan daya beli ancam pertumbuhan ekonomi*. BBC Indonesia.
- Lim, C. (2007). The Application of an Ensemble of Boosted Elman Networks to Time Series Prediction: A Benchmark Study.

- Mulyana. (2014). *POLA NILAI TUKAR RUPIAH TERHADAP USD BERDASARKAN PROSES ARCH*.
- Pangaribuan, J. J. (2016). MENDIAGNOSIS PENYAKIT DIABETES MELITUS DENGAN MENGGUNAKAN METODE EXTREME LEARNING MACHINE.
- Paratu. (2016). In D. Estoatnowo, *Klasifikasi Status Kelulusan Mahasiswa Menggunakan Metode CHAID dan Algoritma C4.5 (Studi Kasus : Mahasiswa Jurusan Statistika Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia)*.
- Pujiati, E., & dkk. (2003). Peramalan Dengan Menggunakan Metode Double Exponential Smoothing Dari Brown. In S. S. Makridakis, *Metode dan Aplikasi Peramalan. Jilid 1*. Jakarta: Binarupa Aksara.
- Purba, R. (1983). *Pengetahuan Perdagangan Luar Negeri Indonesia*. Jakarta: Pustaka Dian.
- Siamat, D. (2005). *pengertian-bi-rate-menurut-para-ahli*. Retrieved from <http://xerma.blogspot.com/2014/04/pengertian-bi-rate-menurut-para-ahli.html>
- Simorangkir, I. (2004). Sistem dan Kebijakan Nilai Tukar.
- Subagyo, P. (1986). *Forecasting Konsep dan aplikasi*. Yogyakarta: BPPE UGM.
- Suseno, I. S. (2004). Sistem dan Kebijakan Nilai Tukar.
- Thionita, V. (2018). Definisi Kurs Adalah.
- Umar, M. (2015). *10 Dampak Negatif pada Masyarakat Melemahnya Rupiah*. Kompasiana.
- Wikipedia. (2017). Retrieved from https://id.wikipedia.org/wiki/Jaringan_saraf_tiruan
- Wikipedia. (2018). *Nilai Tukar*. Retrieved from https://id.wikipedia.org/wiki/Nilai_Tukar

LAMPIRAN

Lampiran A. Data Penelitian

Tanggal	Kurs.Jual
05/01/2009	11005
06/01/2009	11105
07/01/2009	10917
08/01/2009	10995
09/01/2009	11105
12/01/2009	11176
13/01/2009	11277
14/01/2009	11224
15/01/2009	11249
16/01/2009	11225
19/01/2009	11219
20/01/2009	11286
21/01/2009	11291
22/01/2009	11267
23/01/2009	11360
27/01/2009	11331
28/01/2009	11408
29/01/2009	11387
30/01/2009	11412
02/02/2009	11759
03/02/2009	11778
04/02/2009	11743
05/02/2009	11847
06/02/2009	11809
09/02/2009	11759
10/02/2009	11834
11/02/2009	11909
12/02/2009	11925
13/02/2009	11844
.	.
.	.
.	.
.	.
.	.
28/06/2019	14212

Lampiran B. Syntax ELM

```
library(forecast)
library(tstools)
kursjual<-read.delim("clipboard")
kursjual

ts.kurs<-
ts(kursjual$Kurs.Jual,start=c(2009,1),end=c(2019,116),freq=24
0)
ts.kurs
View(ts.kurs)
library(tseries)
ts.plot(ts.kurs, main="plot kurs", col=10)

data.train>window(ts.kurs,start=c(2009,1), end=c(2016,243))
data.train1=ts(data.train)
data.train1
plot(data.train1)
dim(as.matrix(data.train1))
data.test>window(ts.kurs,start=c(2016,244),end=c(2019,116))
data.test1=ts(data.test)
data.test1
plot(data.test1)
dim(as.matrix(data.test1))

library(nnfor)

fit<-
elm(data.test1,hd=100,type=c("lasso","ridge","step","lm"),
reps=20,comb=c("median","mean","mode"),lags=NULL,keep=NULL,di
fforder=NULL,outplot=TRUE
,sel.lag=c(TRUE,FALSE),direct=c(FALSE,TRUE),allow.det.season=
TRUE,
det.type=c("auto","bin","trg"),xreg=NULL,
xreg.lags=NULL, xreg.keep=NULL, barebone=c(FALSE,TRUE))

fit
frc <- forecast(fit,h=30)
frc
library(plotrix)
plot(fit)
plot(frc)
```