

SKRIPSI

**PERAMALAN MENGGUNAKAN METODE
EXTREME LEARNING MACHINE
(STUDI KASUS : NILAI TUKAR PETANI
PROVINSI SULAWESI SELATAN TAHUN 2015- 2021)**

Disusun dan diajukan oleh

NURHAEDAH

H011171013



**PROGRAM STUDI MATEMATIKA DEPARTEMEN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN**

MAKAhSSAR

2023

**PERAMALAN MENGGUNAKAN METODE
EXTREME LEARNING MACHINE
(STUDI KASUS : NILAI TUKAR PETANI
PROVINSI SULAWESI SELATAN TAHUN 2015- 2021)**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Sains
pada Program Studi Matematika Departemen Matematika Fakultas
Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin**

NURHAEDAH

H011171013

**PROGRAM STUDI MATEMATIKA DEPARTEMEN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN**

MAKASSAR

2023

LEMBAR PENGESAHAN

PERAMALAN MENGGUNAKAN METODE *EXTREME*
LEARNING MACHINE
(STUDI KASUS : NILAI TUKAR PETANI PROVINSI
SULAWESI SELATAN TAHUN 2015- 2021)

Disusun dan diajukan oleh

NURHAEDAH

H011171013

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka
Penyelesaian Studi Program Sarjana Program Studi Matematika Fakultas
Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin

pada tanggal, 17 Maret 2023

dan dinyatakan telah memenuhi syarat kelulusan.

Menyetujui,

Pembimbing Utama,

Pembimbing Pertama,


Dr. Khaeruddin, M.Sc.
NIP. 196509141991031003


Dr. Amran, S.Si., M.Si.
NIP. 197011011998021001

Ketua Program Studi,


Prof. Dr. Nurdin, S.Si., M.Si.
NIP. 1970088072000031002



PERNYATAAN KEASLIAN

Yang bertanda tangan di bawah ini :

Nama : Nurhaedah
NIM : H011171013
Program Studi : Matematika
Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul

Peramalan Menggunakan Metode *Extreme Learning Machine*

(Studi Kasus: Nilai Tukar Petani Provinsi Sulawesi Selatan Tahun 2015-2021)

adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alih tulisan orang lain bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri.

Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Makassar, 17 Maret 2023

Yang menyatakan,

Nurhaedah

NIM. H011171013



KATA PENGANTAR

Segala syukur penulis panjatkan kehadirat Allah Subhanahu Wa ta'ala, karena atas berkat dan rahmat-Nya penulis mampu menyelesaikan skripsi ini. Penulisan skripsi ini dilakukan dalam rangka memenuhi salah satu syarat untuk mencapai gelar Sarjana Sains. Penulis menyadari bahwa skripsi ini tidak dapat terselesaikan tanpa bantuan dan bimbingan dari berbagai pihak, dari masa perkuliahan sampai pada penyusunan skripsi. Oleh karena itu, pada kesempatan ini dengan segala kerendahan hati penulis menyampaikan terima kasih yang setulus-tulusnya kepada:

1. Prof. Dr. Ir. Jamaluddin Jompa, M.Sc., selaku Rektor Universitas Hasanuddin beserta seluruh jajarannya dan Dr. Eng. Amiruddin, M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin beserta seluruh jajarannya.
2. Prof. Dr. Nurdin, S.Si., M.Si., selaku Ketua Departemen Matematika serta segenap dosen pengajar dan staf Departemen Matematika yang telah memberikan ilmu dan kemudahan kepada penulis selama masa perkuliahan.
3. Dr. Khaeruddin, M.Sc. selaku dosen pembimbing utama dan Dr. Amran, S.Si., M.Si. selaku dosen pembimbing pertama, yang telah meluangkan waktunya untuk dapat membimbing, memberikan saran dan arahan dalam penyusunan skripsi ini.
4. Prof. Dr. Budi Nurwahyu, M.S. selaku Tim Penguji sekaligus penasehat akademik. Terima kasih atas segala nasehat dan masukan selama menempuh pendidikan sarjana ini serta Jusmawati Massalesse, S.Si., M.Si. selaku Tim Penguji, terima kasih atas saran yang telah diberikan dalam penyusunan skripsi ini.
5. Bapak Hamrah dan Ibu Salma, kedua orang tua penulis yang telah memberikan dukungan baik moril maupun materil yang tidak henti-hentinya.
6. Adik-adik kandung penulis yaitu Nursyahidah dan Inna Ramadhani yang selalu mau diganggu dan mau direpotkan.
7. Teman-teman pengurus FSUA periode 2023/2023, yang sudah menjadi tempat belajar dan tempat untuk menciptakan pengalaman berorganisasi.

8. Teman-teman sehalakah tarbiyah yaitu Kak Darmawali, Nirma, Nining, Hikmah, Kak Sukma, Risda yang selalu kebersamai dalam men-charge keimanan setiap pekannya. Dan juga teman-teman sehalakah tahsin yaitu Kak Cici dan Kak Asse kebersamai untuk mendekatkan diri dengan Al-Quran.
9. Teman seperjuangan skripsi yaitu Kak Daya, MJ, Sarti, Upi, Fira, yang selalu kebersamai dalam mengerjakan tugas akhir.
10. Teman-teman sebangku kuliah yaitu Uni, Ayu, Yuni, Nanda, Sumarni, Mutho yang selalu membantu dalam mengatasi masalah perkuliahan.
11. Teman-teman setempat kerja yaitu Mam Ros, Kak Iga, Kak Sinar, Kak Tutut, dan Rara yang menemani ditempat kerja dan memberikan pengalaman di dunia kerja sebelum lulus kuliah.

Akhir kata, penulis berharap Tuhan Yang Maha Esa berkenan membalas segala kebaikan semua pihak yang telah membantu. Semoga skripsi ini membawa manfaat bagi pengembangan ilmu.

Makassar, 17 Maret 2023

Nurhaedah

**PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK
KEPENTINGAN AKADEMIS**

Sebagai civitas akademik Universitas Hasanuddin, saya yang bertanda tangan di bawah ini:

Nama : Nurhaedah
NIM : H011171013
Program Studi : Matematika
Departemen : Matematika
Fakultas : Matematika dan Ilmu Pengetahuan Alam
Jenis Karya : Skripsi

demikian pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Hasanuddin **Hak Bebas Royalti Noneksklusif** (*Non-exclusive Royalty- Free Right*) atas karya ilmiah saya yang berjudul:

Peramalan Menggunakan Metode *Extreme Learning Machine*

(Studi Kasus: Nilai Tukar Petani Provinsi Sulawesi Selatan Tahun 2015-2021)

beserta perangkat yang ada (jika diperlukan). Terkait dengan hal di atas, maka pihak universitas berhak menyimpan, mengalih-media/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya,

Dibuat di Makassar pada tanggal 17 Maret 2023

Yang menyatakan,

Nurhaedah

ABSTRAK

Nilai tukar petani merupakan salah satu alat bantu ukur untuk melihat dinamika tingkat kesejahteraan petani. Peningkatan nilai tukar petani dapat dilakukan dengan cara meningkatkan indeks harga yang diterima petani, namun hal ini dapat memicu inflasi. Oleh karena itu, perlu digunakan metode peramalan untuk menggambarkan nilai tukar petani pada masa yang akan datang agar pemerintah memiliki gambaran mengenai nilai tukar petani dimasa yang akan datang sehingga dapat dijadikan tolok ukur dalam pengambilan keputusan pemerintah guna meningkatkan pembangunan di bidang pertanian. Salah satu metode peramalan yang bisa digunakan adalah metode *Extreme learning machine* (ELM). Metode ini memiliki kelebihan berupa *learning speed* yang cepat dan mampu menghasilkan *good generalization performance*. Pada penelitian ini diperoleh model arsitektur jaringan ELM terbaik dengan parameter-parameter yang optimal adalah menggunakan fungsi aktivasi linear dengan *neuron* pada *input layer* sebanyak 4 *neuron*, *neuron* pada *hidden layer* sebanyak 10 dan menggunakan data 2 tahun terakhir. Dengan menggunakan parameter-parameter tersebut diperoleh diperoleh tingkat akurasi antara data aktual dengan data hasil peramalan nilai tukar petani pada tahun 2022 yaitu sebesar 1.34609 % sehingga dapat disimpulkan model arsitektur jaringan yang dibangun dalam kinerja metode *extreme learning machine baik* digunakan untuk peramalan ke masa akan mendatang. Nilai evaluasi yang dihasilkan mempunyai kriteria MAPE < 10% yang merupakan peramalan sangat baik.

Kata Kunci : Nilai Tukar Petani, *Extreme Learning Machine*, Peramalan

ABSTRACT

The farmer's exchange rate is one of the measuring tools to see the dynamics of the level of farmer welfare. Increasing farmer exchange rates can be done by increasing the price index received by farmers, but this can trigger inflation. Therefore, it is necessary to use forecasting methods to describe future farmer exchange rates so that the government has an overview of future farmer exchange rates so that they can be used as benchmarks in making government decisions to increase development in agriculture. One of the forecasting methods that can be used is the Extreme Learning Machine (ELM) method. This method has the advantage of fast learning speed and is able to produce good generalization performance. In this study, the best ELM network architecture model was obtained with optimal parameters using a linear activation function with 4 neurons in the input layer, 10 neurons in the hidden layer and using data from the last 2 years. By using these parameters, it is obtained that the level of accuracy between the actual data and the forecast data of farmers' exchange rates in 2022 is 1.34609% so that it can be concluded that the network architecture model built in the performance of the extreme learning machine method is good for forecasting into the future. The resulting evaluation value has MAPE criteria <10% which is a very good forecast.

Keywords: Farmers Exchange Rate, Extreme Learning Machine, Forecasting

DAFTAR ISI

HALAMAN SAMPUL	i
HALAMAN JUDUL.....	ii
PERNYATAAN KEASLIAN.....	Error! Bookmark not defined.
LEMBAR PENGESAHAN	iii
KATA PENGANTAR	iv
PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS	vii
ABSTRAK	viii
ABSTRACT.....	ix
DAFTAR ISI.....	x
DAFTAR NOTASI.....	xiii
DAFTAR TABEL.....	xv
DAFTAR GAMBAR	xvi
DAFTAR LAMPIRAN.....	xvii
BAB 1	1
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
1.6 Sistematika Penulisan.....	4
BAB II.....	6
TINJAUAN PUSTAKA	6
2.1 <i>State of the Art</i>	6
2.2 Nilai Tukar Petani	7
2.2.1 Konsep dan definisi	7
2.2.2 Arti Angka NTP.....	8
2.2.3 Perhitungan It, Ib, dan NTP.....	8
2.2.4 Diagram Timbang.....	9
2.2.5 Kegunaan dan Manfaat	10
2.3 Peramalan (<i>forecasting</i>).....	10
2.4 Analisis Korelasi	11

2.5 <i>Machine learning</i>	12
2.6 Jaringan Syaraf Tiruan	12
2.7 Normalisasi Data	15
2.8 Denormalisasi Data	16
2.9 Metode <i>Extreme learning machine</i>	16
2.9.1 Algoritma ELM	18
2.10 Matriks.....	20
2.11 <i>Moore-Penrose Generalized Inverse</i>	21
2.12 <i>Minimum Norm Least-Square</i> dari Bentuk Umum Sistem Linear	25
2.13 Pemilihan Model Terbaik	26
4.14 Pengujian Model.....	27
4.14.1 Pengujian fungsi aktivasi dan jumlah <i>neuron hidden layer</i>	27
4.14.2 Pengujian kombinasi jumlah <i>neuron input</i> dan variasi jumlah data...	27
BAB III.	28
METODOLOGI PENELITIAN	28
3.1 Jenis dan Sumber Data	28
3.2 Identifikasi Variabel	28
3.2.1. Variabel Masukan	28
3.2.2. Variabel Keluaran	28
3.3 Tahapan Penelitian	28
3.4 Alur Kerja Penelitian	31
3.4.1 Alur Penelitian	31
3.4.2 Alur Proses Pelatihan dan Pengujian	32
BAB IV.	33
HASIL DAN PEMBAHASAN.....	33
4.1 Eksplorasi Data.....	33
4.2 Korelasi data.....	39
4.3 Perhitungan Secara Manual.....	41
4.4 Pengolahan Data.....	48
4.4.1 <i>Preprocessing</i> Data.....	48
4.4.1.1 Membersihkan data	48
4.4.1.2 Pembagian Data	50
4.4.1.3. Normalisasi Data.....	50
4.4.2 Proses <i>Training</i>	51

4.3.2.1. Proses <i>Testing</i>	52
4.5 Pengujian Model.....	53
4.5.1 Pengujian fungsi aktivasi dan jumlah <i>neuron hidden layer</i>	53
4.5.2 Pengujian kombinasi jumlah <i>neuron input</i> dan variasi jumlah data.....	55
4.6 Peramalan Nilai Tukar Petani.....	57
BAB V.....	59
KESIMPULAN DAN SARAN.....	59
5.1 Kesimpulan.....	59
5.2 Saran.....	59
DAFTAR PUSTAKA	60

DAFTAR NOTASI

NTP_t	: Nilai tukar petani periode t
NTP_{t-1}	: Nilai tukar petani periode $t - 1$
P_t	: Perubahan NTP periode t
I_t	: Indeks harga yang diterima petani
I_b	: Indeks harga yang dibayar petani
P_{ti}	: Harga bulan ke- t untuk jenis barang ke- i
$P_{(t-1)i}$: Harga bulan ke- $(t-1)$ untuk jenis barang ke- i
$P_{ti}/P_{(t-1)i}$: Relatif harga bulan ke- t untuk jenis barang ke- i
P_{oi}	: Harga pada tahun dasar untuk jenis barang ke- i
Q_{oi}	: Kuantitas pada tahun dasar untuk jenis barang ke- i
m	: Banyaknya jenis barang yang tercakup dalam paket komoditas
ρ_{xy}	: Korelasi antara dua variabel
$Cov(x, y)$: Kovarian dari kedua variabel
σ_x	: Standar deviasi dari variabel x
σ_y	: Standar deviasi dari variabel y
X	: Nilai data setelah denormalisasi
X_p	: Nilai data <i>output</i> sebelum denormalisasi
$\min\{X_p\}$: Data minimum pada data set sebelum normalisasi
$\max\{X_p\}$: Data maksimum pada data set sebelum normalisasi
i	: Baris
j	: Kolom
w	: Bobot/ <i>weight</i>

x	: Data masukan yang digunakan
\mathbf{b}	: Bias
\mathbf{H}_{train}	: Matriks <i>hidden layer</i> pada proses <i>training</i>
\hat{Y}_{test}	: Hasil peramalan pada proses <i>testing</i>
H_{test}	: <i>Output hidden layer</i> pada proses <i>testing</i>
β	: <i>Output weight</i> dari proses <i>training</i>
Y_t	: Data sebenarnya periode t
\hat{Y}_t	: Data peramalan periode t
n	: Ukuran pengamatan

DAFTAR TABEL

Tabel 2.1. Interpretasi Terhadap Koefisien Korelasi.....	12
Tabel 4.1 Notasi variabel <i>input</i> dan <i>output</i>	33
Tabel 4.2 Persentase perubahan NTP provinsi Sulawesi Selatan	35
Tabel 4.3 NTP Provinsi Sulawesi Selatan dengan tahun dasar yang sama	36
Tabel 4.4 Persentase perubahan NTP Provinsi Sulawesi Selatan.....	37
Tabel 4.5 Koefisien korelasi variabel <i>input</i> terhadap terhadap variabel <i>output</i> ...	40
Tabel 4.6 Data sampel.....	41
Tabel 4.7 Data hasil normalisasi	41
Tabel 4.8 Data latih	42
Tabel 4.9 Data uji.....	42
Tabel 4.10 Matriks bobot	43
Tabel 4.11 Matriks bias.....	43
Tabel 4.12 Matriks inialisasi.....	44
Tabel 4.13 Matriks <i>hidden layer</i>	44
Tabel 4.14 Matriks \mathbf{H}^T	45
Tabel 4.15 Matriks $\mathbf{H}^T \mathbf{H}$	45
Tabel 4.16 Matriks $(\mathbf{H}^T \mathbf{H})^{-1}$	45
Tabel 4.17 Matriks \mathbf{H}^+	46
Tabel 4.18 Matriks $\boldsymbol{\beta}$	46
Tabel 4.19 Matriks inialisasi data uji	47
Tabel 4.20 Matriks <i>hidden layer</i> data uji	47
Tabel 4.21 Hasil peramalan	47
Tabel 4.22 Hasil peramalan setelah denormalisasi	48
Tabel 4.23 nilai MAPE pada proses <i>testing</i> berdasarkan fungsi aktivasi dan jumlah <i>neuron hidden layer</i>	55
Tabel 4.24 nilai MAPE proses <i>testing</i> pada masing-masing <i>neuron hidden layer</i> tiap varasi data.....	56
Tabel 4.25 Nilai peramalan nilai tukar petani Sulawesi Seelatan tahun 2022 ...	58

DAFTAR GAMBAR

Gambar 2.1. Arsitektur jaringan syaraf tiruan	13
Gambar 3.1 Diagram alur kerja penelitian.....	31
Gambar 3.2 Diagram alir proses pelatihan dan pengujian ELM	32
Gambar 4.1 Grafik nilai tukar petani Sulawesi Selatan pada bulan Januari 2015 hingga Desember 2021.....	34
Gambar 4.2 Grafik data nilai tukar petani Sulawesi Selatan pada bulan Januari 2015 hingga Desember 2021 dengan 2018 sebagai tahun dasar.....	37
Gambar 4.3 Grafik indeks harga yang dibayar petani (Ib), diterima petani (It) dan nilai tukar usaha pertanian (NTUP).....	38
Gambar 4.4 Grafik konsumsi rumah tangga	38
Gambar 4.5 Grafik biaya produksi & penambahan barang modal.....	39
Gambar 4.6 Output mendeteksi <i>Missing Value</i>	49
Gambar 4.7 Output melihat info/deskripsi dataset	49
Gambar 4.8 Grafik pada proses <i>training</i>	52
Gambar 4.9 Grafik pada proses <i>testing</i>	53
Gambar 4.10 Grafik pengujian berdasarkan fungsi aktivasi dengan (a) <i>training</i> dan (b) <i>testing</i>	54
Gambar 4.11 Nilai MAPE pengujian berdasarkan kombinasi jumlah <i>neuron</i> Pada <i>input layer</i>	56
Gambar 4.12 Grafik peramalan variabel X1 dengan menggunakan SPSS.....	57
Gambar 4.13 Grafik hasil peramalan nilai tukar petani provinsi Sulawesi Selatan	58

DAFTAR LAMPIRAN

Lampiran 1. Nilai variabel <i>input</i> dan variabel <i>output</i> pada bulan Januari 2015 hingga Desember 2021.....	62
Lampiran 2. Nilai variabel <i>input</i> dan variabel <i>output</i> pada bulan Januari 2015 hingga Desember 2021 dengan tahun 2018 sebagai tahun dasar	72
Lampiran 3. Normalisasi data	76
Lampiran 4. Rata-rata MAPE pengujian berdasarkan fungsi aktivasi dan jumlah <i>neuron</i> pada <i>hidden layer</i>	80
Lampiran 5. Nilai MAPE berdasarkan kombinasi jumlah <i>neuron input</i> dan variasi jumlah data yang digunakan	83
Lampiran 6. Hasil peramalan keadaan setiap variabel <i>input</i>	84
Lampiran 7. <i>Source Code Program</i>	89

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Sektor pertanian merupakan salah satu motor penggerak utama perekonomian Provinsi Sulawesi Selatan. Hal ini menyebabkan provinsi tersebut selalu memprogramkan pembangunan pertanian dengan hakikatnya bertujuan untuk kesejahteraan masyarakat petani baik sekedar mampu mencukupi kebutuhan sehari-hari maupun demi peningkatan kesejahteraan petani itu sendiri. Salah satu alat bantu ukur untuk melihat dinamika tingkat kesejahteraan petani adalah nilai tukar petani atau biasa disingkat dengan NTP. NTP berkaitan dengan kemampuan dan daya beli petani dalam membiayai hidup rumah tangganya. Apabila daya beli petani karena pendapatan yang diterima dari kenaikan harga produksi pertanian yang dihasilkan lebih besar dari kenaikan harga barang yang dibeli maka hal ini menunjukkan bahwa daya dan kemampuan petani lebih baik atau tingkat pendapatan petani lebih meningkat (Elizabeth, 2000).

Nilai tukar petani adalah angka perbandingan antara indeks harga yang diterima petani dengan indeks harga yang dibayar petani yang dinyatakan dalam persentase. Indeks harga yang diterima petani adalah indeks harga yang menunjukkan perkembangan harga produsen atas hasil produksi petani. Indeks harga yang dibayar petani adalah indeks harga yang menunjukkan perkembangan harga kebutuhan rumah tangga petani, baik untuk konsumsi rumah tangga maupun untuk proses produksi pertanian. Peningkatan indeks harga yang diterima petani merupakan hasil dari kebijakan Kementerian Pertanian dalam upaya perlindungan harga komoditas pertanian, sedangkan peningkatan indeks harga yang dibayar petani merupakan hasil kebijakan diluar kendali Kementerian Pertanian. Peningkatan NTP dapat dilakukan dengan cara meningkatkan indeks harga yang diterima petani, namun hal ini dapat memicu inflasi. Oleh sebab itu, untuk meningkatkan NTP perlu diupayakan agar indeks harga yang dibayar petani peningkatannya tidak terlalu progresif. Indeks harga yang diterima petani terdiri dari beberapa kelompok antara lain yaitu tanaman pangan, tanaman hortikultura, tanaman perkebunan rakyat, peternakan, dan perikanan, sedangkan pada indeks

harga yang dibayar petani terdiri dari kelompok konsumsi rumah tangga, biaya produksi dan penambahan barang modal (Widya, 2018).

NTP merupakan salah satu indikator untuk melihat tingkat kemampuan/daya beli petani di pedesaan. NTP juga menunjukkan daya tukar (*terms of trade*) dari produk pertanian dengan barang dan jasa yang dikonsumsi maupun untuk biaya produksi. NTP nasional Februari 2022 sebesar 108,83 atau naik 0,15 % dibanding NTP bulan sebelumnya. Kenaikan NTP dikarenakan indeks harga yang diterima petani (It) naik sebesar 0,26 % lebih tinggi dibandingkan kenaikan indeks harga yang dibayar petani (Ib) sebesar 0,11 %. Pada Februari 2022, NTP Provinsi Riau mengalami kenaikan tertinggi (2,50 %) dibandingkan kenaikan NTP provinsi lainnya. Sebaliknya, NTP Provinsi Sumatera Utara mengalami penurunan terbesar (0,72 %) dibandingkan penurunan NTP provinsi lainnya. Pada Februari 2022 terjadi penurunan indeks konsumsi rumah tangga (IKRT) di Provinsi Sulawesi Selatan sebesar 0,01 % yang disebabkan oleh penurunan indeks pada kelompok pengeluaran makanan, minuman dan tembakau dan kelompok pengeluaran informasi, komunikasi, dan jasa keuangan. Nilai tukar usaha rumah tangga pertanian (NTUP) nasional Februari 2022 sebesar 108,53 atau turun 0,12 % dibanding NTUP bulan sebelumnya.

Nilai tukar petani berfluktuasi dari waktu ke waktu. Pada Februari 2022, NTP di Sulawesi Selatan secara umum mengalami penurunan sebesar 0.53 % dibandingkan dengan bulan sebelumnya. NTP Januari 2022 sebesar 100.74 turun menjadi 100.20 pada Februari 2022. Penurunan NTP tersebut terjadi karena penurunan indeks yang diterima petani sementara indeks dibayar petani mengalami peningkatan. Indeks yang diterima petani mengalami penurunan sebesar 0.32 % sementara indeks dibayar petani mengalami peningkatan sebesar 0.21 %. Padahal yang diharapkan seharusnya NTP dari waktu ke waktu selalu mengalami kenaikan. Oleh karena itu, perlu digunakan metode peramalan untuk menggambarkan NTP pada masa yang akan datang agar pemerintah memiliki gambaran mengenai NTP dimasa yang akan datang sehingga dapat dijadikan tolok ukur dalam pengambilan keputusan pemerintah guna meningkatkan pembangunan di bidang pertanian. Dalam perencanaan ramalan tentunya dibutuhkan ketepatan dalam memilih metode. Banyak metode yang digunakan untuk memperoleh hasil peramalan yang baik dan akurat. Metode-

metode tersebut diantaranya adalah dengan Arch, Garch, Jaringan Syaraf Tiruan (JST), dan lain-lain.

Metode JST merupakan sebuah metode yang mengadopsi sistem pemrosesan informasi pada sistem syaraf biologis yang ada pada manusia. Banyak penelitian menyimpulkan bahwa metode JST lebih baik daripada metode-metode peramalan/prediksi konvensional. Huang (2006) mengemukakan bahwa salah satu metode yang merupakan pengembangan dari Metode JST *feed-forward* dengan *satu hidden layer* adalah *Extreme learning machine* (ELM). Metode ini dikembangkan untuk mengatasi kelemahan dari metode-metode JST sebelumnya dalam hal learning speed. Kelemahan ini disebabkan karena semua bobot *input* dan bias pada jaringan ditentukan secara iteratif. Pada metode ELM, bobot *input* dan bias mula-mula ditentukan secara acak. Setelah itu, bobot akhir dicari menggunakan *Moore-Penrose Generalized Inverse*. Hal ini menyebabkan ELM memiliki learning speed yang lebih cepat.

Berdasarkan uraian di atas, penulis tertarik untuk melakukan penelitian terkait penggunaan metode *extreme learning machine* untuk melakukan prediksi terkait nilai tukar petani provinsi Sulawesi Selatan dan menuangkan hasilnya dalam bentuk tulisan skripsi dengan judul "**Peramalan Menggunakan Metode *Extreme learning machine* (Studi Kasus: Nilai Tukar Petani Provinsi Sulawesi Selatan Tahun 2015- 2021)**"

1.2 Rumusan Masalah

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

1. Bagaimana model arsitektur jaringan dari *Extreme learning machine* yang optimal dalam memprediksi nilai tukar petani provinsi Sulawesi Selatan tahun 2015-2021 ?
2. Bagaimana kinerja *Extreme learning machine* dalam memprediksi nilai tukar petani provinsi Sulawesi Selatan ?

1.3 Batasan Masalah

Adapun batasan-batasan yang digunakan dalam penelitian tugas akhir ini adalah sebagai berikut:

1. Data yang digunakan yaitu data nilai tukar petani provinsi Sulawesi Selatan dari tahun 2015-2021 dengan periode waktu bulanan.
2. Menggunakan metode *Extreme learning machine*.
3. Software yang digunakan adalah python dan spss.
4. Akurasi hasil peramalan dihitung menggunakan Mean Absolute Percentage Error (MAPE).

1.4 Tujuan Penelitian

Dari permasalahan yang telah diajukan sebelumnya maka tujuan dari penelitian ini sebagai berikut:

1. Memperoleh model arsitektur jaringan dari *Extreme learning machine* yang optimal dalam memprediksi nilai tukar petani provinsi Sulawesi Selatan tahun 2015-2021.
2. Mengetahui kinerja *Extreme learning machine* dalam memprediksi nilai tukar petani provinsi Sulawesi Selatan.

1.5 Manfaat Penelitian

Adapun manfaat yang diharapkan dari hasil penelitian ini adalah sebagai berikut:

1. Memberikan informasi hasil peramalan nilai tukar petani pada periode yang akan datang sehingga dapat dilakukan antisipasi untuk mencegah menurunnya daya beli petani dan juga sebagai bahan pertimbangan bagi instansi terkait untuk menentukan kebijakan kedepannya.
2. Memberikan kontribusi pengetahuan mengenai penerapan *metode Extreme learning machine* untuk prediksi nilai tukar petani.
3. Sebagai salah satu sarana informasi dan referensi bagi semua pihak yang tertarik dengan masalah yang dibahas dalam penelitian ini.

1.6 Sistematika Penulisan

Tugas akhir ini terdiri dari lima bab dengan sistematika penulisan sebagai berikut:

BAB I PENDAHULUAN

Bab ini berisi latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian dan sistematika penulisan.

BAB II TINJAUAN PUSTAKA

Bab ini berisi teori-teori yang berhubungan dengan permasalahan tugas akhir. Teori-teori tersebut berasal dari literatur-literatur. Adapun teori-teori yang akan dibahas dalam bab ini adalah nilai tukar petani, peramalan, analisis korelasi, *machine learning*, jaringan syaraf tiruan, metode *Extreme learning machine* (ELM), dan pemilihan model terbaik.

BAB III METODE PENELITIAN

Bab ini berisi penjelasan mengenai ruang lingkup dan metode yang digunakan dalam skripsi ini. Adapun metode yang dibahas adalah jenis dan sumber data, objek penelitian, tahapan penelitian, dan alur kerja.

BAB IV HASIL DAN PEMBAHASAN

Bab ini berisi hasil penelitian yang telah dilakukan serta pembahasannya.

BAB V PENUTUP

Bab ini berisi kesimpulan dan saran dari hasil dan pembahasan masalah yang penelitian.

BAB II

TINJAUAN PUSTAKA

2.1 *State of the Art*

Penelitian terkait metode yang digunakan dalam penelitian ini yaitu sebagai berikut :

Agustina dkk., (2005) dengan judul penelitian “Penerapan Metode *Extreme learning machine* untuk Peramalan Permintaan” menunjukkan bahwa metode ELM memiliki tingkat akurasi yang lebih baik dibandingkan dengan metode konvensional seperti *Moving Average* dan *Exponential Smoothing*. Berdasarkan hasil uji coba terhadap ELM dengan fungsi aktivasi dan jumlah *hidden neuron* yang berbeda, maka pada penelitian ini ELM menghasilkan *output* optimal pada fungsi aktivasi purelin dengan jumlah *hidden neuron* lima untuk data kaos, dan jumlah *hidden neuron* tiga untuk data pin. Metode ELM menghasilkan *output* peramalan dengan tingkat kesalahan yang rendah yaitu MAPE 0.0042 % pada produk kaos dan 0.0095% pada produk pin. Metode peramalan *Moving Average* mempunyai tingkat kesalahan 19.19% pada produk kaos dan 55.43% pada produk pin sedangkan pada *Exponential Smoothing* mempunyai tingkat kesalahan 32.93% pada produk kaos dan 11.39% pada produk pin.

Khusnul Khotimah dkk., (2010) dengan judul penelitian “Kinerja Metode *Extreme learning machine* (ELM) Pada Sistem Peramalan” menunjukkan bahwa dengan menggunakan metode ELM diperoleh nilai MSE dan MAPE terendah dibandingkan dengan menggunakan algoritma *Backpropagation*. Metode ELM menggunakan konfigurasi *hidden layer* berjumlah 4, epoch 1000, pengaturan *range* antara -0,4 – 0,4 menghasilkan rata-rata nilai MSE = 1,100% dan MAPE = 0.31% sedangkan proses pembelajaran menggunakan metode *Backpropagation* dengan parameter perubahan *hidden layer* berjumlah 4, E-poch maksimal 3000 , dan pengaturan momentum 0,4 mencapai nilai yang terbaik. Parameter tersebut menghasilkan nilai *error* yang cukup baik saat sistem melakukan pengujian yaitu MSE = 3.1933% dan MAPE = 0,96 %.

Fardani dkk., (2015) dengan judul penelitian “Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode *Extreme learning machine* (Studi Kasus : Poli Gigi Rsu Dr. Wahidin Sudiro Husodo Mojokerto) menghasilkan suatu aplikasi sistem pendukung keputusan untuk meramalkan jumlah kunjungan pasien. Melalui uji coba menggunakan 116 data *testing* berdasarkan fungsi aktivasi sigmoid biner dengan jumlah *hidden layer* sebanyak 7 unit dan Epoch 500 diperoleh hasil optimal MSE sebesar 0.02.

Fikriya dkk., (2017) dengan judul penelitian “Implementasi *Extreme learning machine* untuk Pengenalan Objek Citra Digital” menggunakan metode *extreme learning machine* dengan 500 *neuron* pada *input layer*, 1250 *neuron* pada *hidden layer*, dan 3 *neuron* 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.

Izati dkk., (2019) dengan judul penelitian “Peramalan Harga Emas Menggunakan *Feed Forward Neural Network* dengan Metode *Extreme learning machine*” menghasilkan model terbaik harga emas dunia adalah model FFNN dengan X_{t-1} sebagai variabel *input* dan dengan jumlah *hidden neurons* sebanyak 7. Model tersebut mampu memberikan hasil pemodelan yang sangat baik pada proses *training* yaitu dengan nilai MAPE sebesar 0,6752% dan mampu memberikan model dengan kemampuan peramalan yang sangat baik dengan MAPE 0,5499 %. Hasil peramalan harga emas dunia (USD/troy ounce) 10 periode ke depan dengan metode *Extreme learning machine* sangat baik karena mendekati dengan nilai aktualnya.

2.2 Nilai Tukar Petani

2.2.1 Konsep dan definisi

Nilai Tukar Petani adalah angka perbandingan antara indeks harga yang diterima petani dengan indeks harga yang dibayar petani yang dinyatakan dalam persentase. Indeks harga yang diterima petani adalah indeks harga yang menunjukkan perkembangan harga produsen atas hasil produksi petani. Indeks harga yang dibayar petani adalah indeks harga yang menunjukkan perkembangan

harga kebutuhan rumah tangga petani, baik untuk konsumsi rumah tangga maupun untuk proses produksi pertanian.

Harga yang diterima petani adalah rata-rata harga produsen dari hasil produksi petani sebelum ditambahkan biaya transportasi/pengangkutan dan biaya pengepakan ke dalam harga penjualannya atau disebut *Farm Gate* (harga di sawah/ladang setelah pemetikan). Pengertian rata-rata harga adalah harga yang bila dikalikan dengan volume penjualan petani akan mencerminkan total uang yang diterima petani tersebut. Data harga tersebut dikumpulkan dari hasil wawancara langsung dengan petani produsen. Harga yang dibayar petani adalah rata-rata harga eceran barang/jasa yang dikonsumsi atau dibeli petani, baik untuk memenuhi kebutuhan rumah tangganya sendiri maupun untuk keperluan biaya produksi pertanian. Data harga barang/jasa untuk keperluan produksi pertanian dan untuk keperluan konsumsi rumah tangga dicatat dari hasil wawancara langsung dengan pedagang atau penjual jasa di pasar terpilih. Data upah buruh tani dikumpulkan dari hasil wawancara langsung dengan petani/buruh tani. (BPS, 2022)

2.2.2 Arti Angka NTP

- NTP > 100, berarti petani mengalami surplus. Harga produksi naik lebih besar dari kenaikan harga konsumsinya. Pendapatan petani naik lebih besar dari pengeluarannya.
- NTP = 100, berarti petani mengalami impas. Kenaikan/penurunan harga produksinya sama dengan persentase kenaikan/penurunan harga barang konsumsi. Pendapatan petani sama dengan pengeluarannya.
- NTP < 100, berarti petani mengalami defisit. Kenaikan harga produksi relatif lebih kecil dibandingkan dengan kenaikan harga barang konsumsinya. Pendapatan petani turun, lebih kecil dari pengeluarannya. (BPS, 2022)

2.2.3 Perhitungan It, Ib, dan NTP

Formula atau rumus yang digunakan pada penghitungan It dan Ib adalah formula Indeks Laspeyres yang dikembangkan (*Modified Laspeyres Indexes*), yaitu :

$$I_t = \frac{\sum_{i=1}^m \frac{P_{ti}}{P_{(t-1)i}} P_{(t-1)i} Q_{oi}}{\sum_{i=1}^m P_{oi} Q_{oi}} \quad (2.1)$$

Keterangan :

I_t = Indeks harga bulan ke-t (It maupun It)

- P_{ti} = Harga bulan ke-t untuk jenis barang ke-i
 $P_{(t-1)i}$ = Harga bulan ke-(t-1) untuk jenis barang ke-i
 $P_{ti}/P_{(t-1)i}$ = Relatif harga bulan ke-t untuk jenis barang ke-i
 P_{oi} = Harga pada tahun dasar untuk jenis barang ke-i
 Q_{oi} = Kuantitas pada tahun dasar untuk jenis barang ke-i
 m = Banyaknya jenis barang yang tercakup dalam paket komoditas

Formula untuk penghitungan NTP :

$$NTP = \frac{I_t}{I_b} \times 100 \quad (2.2)$$

Keterangan :

- NTP = Nilai Tukar Petani
 I_t = Indeks harga yang diterima petani
 I_b = Indeks harga yang dibayar petani

Formula untuk perubahan NTP :

$$P_t = \frac{NTP_t - NTP_{t-1}}{NTP_{t-1}} \times 100 \quad (2.3)$$

atau persamaan (2.3) dapat ditulis menjadi

$$\begin{aligned}
 P_t &= \left(\frac{NTP_t}{NTP_{t-1}} - \frac{NTP_{t-1}}{NTP_{t-1}} \right) \times 100 \\
 P_t &= \left(\frac{NTP_t}{NTP_{t-1}} - 1 \right) \times 100 \\
 \left(\frac{NTP_t}{NTP_{t-1}} - 1 \right) \times 100 &= P_t \\
 \left(\frac{NTP_t}{NTP_{t-1}} - 1 \right) &= \frac{P_t}{100} \\
 \frac{NTP_t}{NTP_{t-1}} &= \frac{P_t}{100} + 1 \\
 NTP_t &= NTP_{t-1} \left(\frac{P_t}{100} + 1 \right) \quad (2.4)
 \end{aligned}$$

Keterangan :

- P_t = Perubahan NTP periode t
 NTP_t = Nilai tukar petani periode t
 NTP_{t-1} = Nilai tukar petani periode $t - 1$ (BPS, 2022)

2.2.4 Diagram Timbang

Penghitungan Indeks Laspeyres yang dikembangkan untuk menghasilkan NTP memerlukan diagram timbang. Ada dua indeks yang digunakan untuk menghasilkan NTP, yaitu indeks harga yang diterima petani (I_t) dan indeks harga yang dibayar petani (I_b).

2.2.4.1 Indeks Harga yang Diterima Petani (It)

Penimbang yang digunakan untuk It adalah nilai produksi yang dijual petani dari setiap jenis komoditas pertanian. Sebagai data pokok untuk penghitungan diagram timbang ini diperlukan tiga macam data yaitu kuantitas produksi, harga produsen, dan persentase nilai komoditas pertanian yang dijual terhadap total nilai produksi (marketed surplus)

2.2.4.2 Indeks Harga yang Dibayar Petani (Ib)

Penimbang setiap jenis barang/jasa yang tercakup dalam pengeluaran konsumsi rumah tangga, biaya produksi dan penambahan barang modal adalah nilai setiap jenis barang yang dibeli petani, termasuk nilai barang yang diproduksi sendiri. Biaya produksi dan penambahan barang modal terdiri dari biaya bibit; pupuk, obat-obatan, dan pakan; biaya sewa dan pengeluaran lainnya; transportasi; barang modal dan upah buruh tani. Penimbang untuk kelompok ini adalah pengeluaran ongkos-ongkos/biaya yang dikeluarkan petani (tidak termasuk ongkos/biaya produksi yang berasal dari produksi sendiri). (BPS, 2022)

2.2.5 Kegunaan dan Manfaat

- Dari Indeks Harga Yang Diterima Petani (It), dapat dilihat fluktuasi harga barang-barang yang dihasilkan petani. Indeks ini digunakan juga sebagai data penunjang dalam penghitungan pendapatan sektor pertanian.
- Dari Indeks Harga Yang Dibayar Petani (Ib), dapat dilihat fluktuasi harga barang-barang yang dikonsumsi oleh petani yang merupakan bagian terbesar dari masyarakat di pedesaan, serta fluktuasi harga barang yang diperlukan untuk memproduksi hasil pertanian. Perkembangan Ib juga dapat menggambarkan perkembangan inflasi di pedesaan.
- NTP mempunyai kegunaan untuk mengukur kemampuan tukar produk yang dijual petani dengan produk yang dibutuhkan petani dalam produksi dan konsumsi rumah tangga.
- Angka NTP menunjukkan tingkat daya saing produk pertanian dibandingkan dengan produk lain. Atas dasar ini upaya produk spesialisasi dan peningkatan kualitas produk pertanian dapat dilakukan. (BPS, 2022)

2.3 Peramalan (*forecasting*)

Peramalan (*forecasting*) adalah suatu kegiatan yang memperkirakan apa yang terjadi pada masa yang akan datang. Peramalan adalah suatu situasi atau kondisi yang diperkirakan terjadi pada masa yang akan datang. Metode peramalan

merupakan cara untuk memperkirakan secara kuantitatif apa yang terjadi di masa yang akan datang dengan dasar data yang relevan pada masa lalu, metode peramalan ini digunakan dalam peramalan yang bersifat objektif (Makridakis, 2008).

Peramalan dalam kehidupan sangat berperan penting, maka dari itu banyak metode yang bisa menyelesaikan permasalahan pada peramalan. Salah satunya adalah metode *Extreme learning machine* (ELM). Peramalan kinerja dengan cara menemukan pola pada data *training* kemudian akan di uji dengan data *testing*.

2.4 Analisis Korelasi

Analisis korelasi digunakan untuk mengetahui derajat hubungan linear antara satu variabel dengan variabel lain. Untuk mengetahui hubungan antar variabel jika data yang digunakan memiliki skala interval atau rasio disebut Korelasi Produk Moment atau Pearson. Dasar pemikiran analisis korelasi Produk Moment adalah perubahan antar variabel, artinya, jika perubahan suatu variabel diikuti perubahan variabel yang lain maka kedua variabel tersebut saling berkorelasi. (Sihombing, 2019).

Nugroho dalam (Sihombing, 2019), menyatakan dalam statistika parametrik, koefisien korelasi yang dikenal luas dan paling sering digunakan adalah koefisien korelasi momen hasil kali Pearson yang dinotasikan dengan r , dimana rumus r adalah sebagai berikut:

$$r = \frac{\sum xy - \frac{(\sum x \sum y)}{n}}{\sqrt{\left(\sum x^2 - \frac{(\sum x)^2}{n}\right) \left(\sum y^2 - \frac{(\sum y)^2}{n}\right)}} \quad (2.5)$$

Selain dengan rumus seperti pada Persamaan (2.5), korelasi juga dapat dicari dengan menggunakan rumus sebagai berikut :

$$\rho_{xy} = \frac{Cov(x,y)}{\sigma_x \sigma_y} \quad (2.6)$$

dimana,

ρ_{xy} = korelasi antara dua variabel

$Cov(x, y)$ = kovarian dari kedua variabel

σ_x = standar deviasi dari variabel x

σ_y = standar deviasi dari variabel y

Koefisien korelasi bisa bernilai positif atau negatif dan nilai koefisien korelasi berkisar antara -1 sampai dengan 1. Korelasi negatif ditunjukkan dengan koefisien korelasi yang bernilai negatif begitu juga sebaliknya korelasi positif ditunjukkan dengan koefisien korelasi yang bernilai positif. Interpretasi terhadap koefisien korelasi ditunjukkan pada tabel 2.1

Tabel 2.1. Interpretasi Terhadap Koefisien Korelasi

Besar Koefisien Korelasi (Positif atau Negatif)	Interpretasi Koefisien Korelasi
0.80-1	Sangat kuat
0.60-0.799	Kuat
0.40-0.599	Cukup Kuat
0.20-0.399	Rendah
0.00-0.199	Sangat rendah

2.5 Machine learning


Secara definisi, *machine learning* adalah cabang dari ilmu kecerdasan buatan yang berfokus pada pembangunan dan studi sebuah sistem agar mampu belajar dari data-data yang diperolehnya. Menurut Arthur Samuel, *machine learning* adalah bidang studi yang memberikan kemampuan program komputer untuk belajar tanpa secara eksplisit diprogram (Fikriya, 2017).

Untuk bisa mengaplikasikan teknik-teknik *machine learning* maka harus ada data. Tanpa data maka algoritma *machine learning* tidak dapat bekerja. Data yang ada biasanya dibagi menjadi dua, yaitu data *training* dan data *testing*. Data *training* digunakan untuk melatih algoritma, sedangkan data *testing* digunakan untuk mengetahui performa algoritma yang telah dilatih sebelumnya ketika menemukan data baru yang belum pernah dilihat (Fikriya, 2017).

2.6 Jaringan Syaraf Tiruan

Jaringan syaraf tiruan adalah salah satu cabang dari *machine learning*. JST merupakan teknik yang digunakan untuk membangun program yang cerdas dengan pemodelan yang mensimulasikan cara kerja jaringan syaraf pada otak manusia. Jadi, JST menggunakan konsep kerja dari syaraf otak manusia untuk menyelesaikan perhitungan pada komputer. Seperti otak manusia, fungsi dari jaringan ditentukan

oleh hubungan antar *neuron*. Hubungan antar *neuron* ini disebut bobot (*weight*). Pola hubungan ini berkaitan erat dengan hubungan antar *layer*. Setiap *layer* terdiri dari sekumpulan *neuron*. Selain itu juga ada *hidden layer* yang terdiri dari *neuron* tersembunyi (Fikriya, 2017). Arsitektur jaringan syaraf tiruan dapat dilihat pada Gambar 2.1



Gambar 2.1. Arsitektur jaringan syaraf tiruan

Secara matematis model jaringan syaraf seperti yang diilustrasikan pada Gambar 2.1 dapat dituliskan seperti pada Persamaan (2.7) dan Persamaan (2.8).

$$Z_j = g(x_1 w_{1j} + \dots + x_n w_{nj}) \quad (2.7)$$

$$Y = g(Z_1 \beta_1 + \dots + Z_p \beta_p + \dots + Z_j \beta_j) \quad (2.8)$$

dimana Z_j adalah nilai *neuron-neuron* pada *hidden layer* yang telah dikenakan fungsi aktivasi, dan Y adalah nilai *neuron-neuron* pada *output layer* yang telah dikenakan fungsi aktivasi(Najar, 2018).

Secara garis besar JST mempunyai dua tahap pemrosesan informasi yaitu tahap pelatihan dan tahan pengujian. Susunan dari *neuron-neuron* dalam lapisan dan pola keterhubungan antar lapisan disebut sebagai arsitektur jaringan. JST memiliki beberapa bagian utama yang menyusunnya antara lain *input*, bias, fungsi aktivasi, *hidden layer*, dan *output*. *Input* merupakan bagian dari jaringan syaraf tiruan yang berperan dalam memberikan informasi/masukkan data yang akan disampaikan ke *neuron* dari informasi tersebut akan diterima dan diproses oleh *neuron* dan akan diberikan nilai bobot (Izati, 2019).

Bias adalah nilai masukan (*input*) yang ditambahkan ke dalam suatu jaringan syaraf tiruan dimana nilainya selalu sama dengan 1. Bias memiliki fungsi

untuk mengubah nilai *threshold* menjadi = 0 (bukan = θ) sedangkan *threshold* adalah sebuah konstanta yang berfungsi sebagai penimbang dalam suatu hubungan dari suatu unit tertentu (Warsito, 2009).

Fungsi aktivasi dalam JST dipakai untuk menentukan *output* suatu *neuron*. Argumen fungsi aktivasi adalah net *input* (kombinasi linier *input* dan bobotnya). Warsito (2009) mengemukakan beberapa fungsi aktivasi yang biasa digunakan pada JST sebagai berikut:

- Fungsi Linear (Identitas/Purelin)

Fungsi identitas akan menghasilkan *output* yang sama dengan *input*nya, fungsi identitas biasa digunakan untuk kasus dengan *output* jaringan berupa bilangan riil (bukan hanya pada *range* [0,1] atau [1,1] dengan fungsi sebagai berikut :

$$f(x) = x \quad (2.9)$$

- Fungsi Sigmoid Biner (*Logistic Sigmoid*)

Fungsi sigmoid biner bernilai antara 0 sampai 1, fungsi sigmoid biner digunakan apabila *output* yang diinginkan merupakan bilangan riil antara 0 sampai 1. Fungsi sigmoid biner dinyatakan sebagai berikut:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.10)$$

- Fungsi Sigmoid Bipolar

Pada dasarnya fungsi sigmoid bipolar mirip dengan fungsi sigmoid biner, hanya saja *output* yang dihasilkan berupa 1 atau -1. Fungsi sigmoid bipolar dirumuskan sebagai berikut: sebagai berikut:

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (2.11)$$

- Fungsi Aktivasi Tangen Hiperbolik (htan)

Fungsi tanh mirip dengan fungsi sigmoid. *Output*nya berkisar dari -1 hingga 1. Fungsi matematis dari fungsi tanh adalah:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.12)$$

- Fungsi Aktivasi Rectified Linear Unit (ReLU)

Fungsi aktivasi linear yang diperbaiki (RELU) adalah fungsi linear sepotong-sepotong yang, jika *inputnya* positif katakanlah x , *outputnya* akan menjadi x . jika tidak, itu menghasilkan nol.

$$f(x) = \max(0, x) \quad (2.13)$$

ReLU digunakan secara luas saat ini, tetapi memiliki beberapa masalah. katakanlah jika kita memiliki *input* kurang dari 0, maka *outputnya* nol, dan jaringan saraf tidak dapat melanjutkan algoritma backpropagation. Masalah ini umumnya dikenal sebagai Dying ReLU. Untuk mengatasi masalah ini, digunakan ReLU versi improvisasi, yang disebut Leaky ReLU.

- Leaky ReLU

Leaky ReLU adalah metode yang paling umum dan efektif untuk memecahkan masalah ReLU yang dying. Ini tidak lain adalah versi perbaikan dari fungsi ReLU. Ini menambahkan sedikit kemiringan dalam kisaran negatif untuk mencegah masalah ReLU.

$$f(x) = \max(0.05, x) \quad (2.14)$$

Hidden layer berfungsi untuk menyalurkan informasi dari *input layer* ke *output layer* dimana sebelumnya informasi tersebut sudah dilakukan pemrosesan untuk memberikan *output* yang optimal. Hasil keluaran proses pada *hidden layer* disebut *output hidden layer*. Informasi *output hidden layer* ini selanjutnya diteruskan ke *output layer*. *Output* merupakan hasil dari semua perhitungan *input* dan bobot-bobot yang diberikan pada *neuron* yang saling berhubungan dengannya. Pada dasarnya *output* merupakan hasil akhir pemrosesan(Izati, 2019).

2.7 Normalisasi Data

Menurut (Agustina, 2005), Normalisasi data adalah mengubah data sesuai kebutuhan menjadi lebih kecil. Transformasi ini merupakan alat untuk *preprocessing* pada data mining. Normalisasi berguna untuk proses menggunakan neural network. Data dinormalisasikan ke dalam interval yang lebih kecil, baik interval (0,1) atau interval (-1,1). Transformasi digunakan untuk mengubah data menjadi interval (0,1) adalah :

$$X = 0,8 \times (X_p - \min\{X_p\}) / (\max\{X_p\} - \min\{X_p\}) + 0,1 \quad (2.15)$$

Namun, jika menginginkan interval (-1,1) maka transformasi yang digunakan untuk mengubah data menjadi interval (-1,1) :

$$X = 2 \times (X_p - \min\{X_p\}) / (\max\{X_p\} - \min\{X_p\}) - 1$$

Keterangan :

X_p = nilai data asli yang belum dinormalisasi

$\min\{X_p\}$ = nilai minimum pada data set

$\max\{X_p\}$ = nilai maksimum pada data set.

2.8 Denormalisasi Data

Menurut (Agustina, 2005), Denormalisasi data adalah mengembalikan data ke bentuk semula. Tahap ini sangat penting untuk dilakukan agar data dari hasil peramalan dengan algoritma ELM dapat dilihat secara mudah dalam membandingkan nilai hasil ramalan dengan nilai aslinya. Berikut ini menunjukkan rumus yang digunakan untuk denormalisasi data di dalam interval (0,1) pada persamaan berikut :

$$X = \frac{(X_p - 0,1) \times (\max\{X_p\} - \min\{X_p\})}{0,8} + \min\{X_p\} \quad (2.16)$$

dan rumus yang digunakan untuk denormalisasi data dalam interval (-1,1) adalah

$$X = 0,5 \times (X_p + 0,1) \times (\max\{X_p\} - \min\{X_p\}) + \min\{X_p\}$$

Keterangan :

X = nilai data setelah denormalisasi

X_p = nilai data *output* sebelum denormalisasi

$\min\{X_p\}$ = data minimum pada data set sebelum normalisasi

$\max\{X_p\}$ = data maksimum pada data set sebelum normalisasi.

2.9 Metode *Extreme learning machine*

Extreme learning machine merupakan metode syaraf tiruan untuk pembelajaran terbaru. Metode ELM diperkenalkan oleh Huang pada tahun 2004. ELM biasanya disebut dengan jaringan syaraf tiruan *feedforward* dengan satu *hidden layer* atau bisa disebut dengan istilah *single hidden layer feedforward neural network* (SLFNs) (Sun, 2008).

Metode pembelajaran ELM digunakan dalam mengatasi beberapa kelemahan dari jaringan saraf tiruan khususnya pada bagian kecepatan pembelajaran atau *learning speed*. Huang mengatakan ada dua alasan kenapa

dalam proses JST *feedforward* lain mempunyai kecepatan pembelajaran atau *learning speed* yang rendah, dibawah ini merupakan beberapa alasan yang dikemukakan :

- 1) Dikarenakan menggunakan *slow gradient based learning algorithm* dalam proses pelatihan data.
- 2) Untuk semua parameter pada jaringan saraf tiruan ditentukan secara *iterative* dengan menggunakan metode pembelajaran tersebut.

Pada pembelajaran *Extreme learning machine* parameter-parameter untuk *input* bobot dan bias dibangkitkan secara acak sehingga pembelajaran ELM memiliki *learning speed* yang cepat dan mampu menghasilkan *good generalization performance*.

Untuk N jumlah sampel yang berbeda $(\mathbf{x}_i, \mathbf{y}_i)$ dimana $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbf{R}^n$ dan $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in \mathbf{R}^m$, SLFNs standar dengan jumlah layer tersembunyi sebanyak \tilde{N} dengan fungsi aktivasi $g(x)$ secara matematis dapat dimodelkan sebagai berikut (Huang, 2006):

$$\sum_{j=1}^{\tilde{N}} \beta_j g(\mathbf{x}_i) = \sum_{j=1}^{\tilde{N}} \beta_j g(\mathbf{w}_j \cdot \mathbf{x}_i + \mathbf{b}_j) = \mathbf{o}_i, i = 1, \dots, N \quad (2.17)$$

dimana $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T$ adalah matriks bobot yang menghubungkan antara *neuron input* dan *neuron* pada layer tersembunyi, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jn}]^T$ adalah vektor bobot yang menghubungkan antara *neuron* pada layer tersembunyi dengan *neuron output* dan \mathbf{b}_j adalah bias dari *neuron* pada layer tersembunyi. $\mathbf{w}_j \cdot \mathbf{x}_i$ merupakan hasil kali dalam \mathbf{w}_j dan \mathbf{x}_i . Asumsikan bahwa *error* yang diharapkan adalah 0 maka ini berarti $\sum_{i=1}^N \|\mathbf{o}_i - \mathbf{y}_i\| = 0$, sehingga persamaan 2.17 menjadi:

$$\sum_{j=1}^{\tilde{N}} \beta_j g(\mathbf{w}_j \cdot \mathbf{x}_i + \mathbf{b}_j) = \mathbf{y}_i, i = 1, \dots, N \quad (2.18)$$

Selanjutnya persamaan 2.18 dapat dituliskan dalam bentuk:

$$\mathbf{H} \beta = \mathbf{Y} \quad (2.19)$$

dimana

$$\mathbf{H}(\mathbf{w}_1, \dots, \mathbf{w}_{\tilde{N}}, \mathbf{b}_1, \dots, \mathbf{b}_{\tilde{N}}, \mathbf{x}_1, \dots, \mathbf{x}_N) = \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + \mathbf{b}_1) & \dots & g(\mathbf{w}_{\tilde{N}} \cdot \mathbf{x}_1 + \mathbf{b}_{\tilde{N}}) \\ \vdots & \dots & \vdots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_N + \mathbf{b}_1) & \dots & g(\mathbf{w}_{\tilde{N}} \cdot \mathbf{x}_N + \mathbf{b}_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}}$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_N \end{bmatrix}_{N \times m} \quad \text{dan} \quad \mathbf{Y} = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix}_{N \times m}$$

Dalam (Huang, 2006), \mathbf{H} disebut matriks *hidden layer output* dari jaringan saraf tiruan, dimana kolom ke- i dari matriks \mathbf{H} adalah *output* dari *neuron* pada layar tersembunyi yang bersesuaian dengan x_1, x_2, \dots, x_N .

Pada aplikasinya proses pelatihan pada metode ELM bertujuan untuk mencari nilai bobot $\boldsymbol{\beta}$. Persamaan 2.18 dimodifikasi maka nilai $\boldsymbol{\beta}$ dapat diperoleh :

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y} \quad (2.20)$$

dimana \mathbf{H}^+ adalah *Moore-Penrose Generalized Inverse* dari matriks \mathbf{H} .

2.9.1 Algoritma ELM

Berikut algoritma metode *Extreme learning machine*:

Preprocessing Data

1. Memasukkan data baik itu data fitur maupun target.
2. Normalisasi data
3. Membagi data menjadi 2 yaitu *training* dan *testing*

Algoritma Training

1. Mendefinisikan matriks data *input* (\mathbf{X}_{train}) berdimensi $m \times j$.
2. Mendefinisikan matriks data *output* (\mathbf{Y}_{train}) berdimensi $m \times 1$.
3. Tetapkan banyaknya *neuron* pada *hidden layer* (d) dan fungsi aktivasi yang akan digunakan.
4. Mendefinisikan matriks bobot (\mathbf{w}) berdimensi $j \times d$ dan bias (\mathbf{b}) berdimensi $1 \times d$.
5. Bangkitkan nilai matriks bobot (\mathbf{w}) dan bias (\mathbf{b}) dalam proses data *training*. Pada proses ini nilai yang diinisialisasi secara *random* 0 sampai 1.
6. Pada langkah selanjutnya yaitu masuk kedalam proses *feedforward*, menghitung matriks inisialisasi dengan menggunakan persamaan berikut :

$$(\mathbf{H}_{init \ i, j}) = \sum_{k=1}^m w_{kj} \cdot x_{ik} + b_{1j} \quad (2.21)$$

dengan

$H_{init \ i \ j}$ = matriks inisialisasi *training*

i = baris

j = kolom

- w = bobot/*weight*
 x = data masukan yang digunakan
 b = bias

7. Selanjutnya menghitung nilai fungsi aktivasi sigmoid dengan persamaan

$$\mathbf{H}_{train} = \frac{1}{1+\exp(-\mathbf{H}_{init})} \quad (2.22)$$

dimana

\mathbf{H}_{train} = matriks *hidden layer* pada proses *training*

8. Langkah selanjutnya masuk ke tahap untuk menghitung *transpose* matriks *hidden layer* (\mathbf{H}_{train}^T).
9. Menghitung matrik *Moore-Penrose Generalized Inverse* dengan rumus

$$\mathbf{H}^+ = (\mathbf{H}_{train}^T \mathbf{H}_{train})^{-1} \mathbf{H}_{train}^T \quad (2.23)$$

10. Selanjutnya menghitung hasil *output weight* dengan rumus dibawah :

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y} \quad (2.24)$$

Algoritma *Testing*

1. Mendefinisikan matriks data *input* (\mathbf{X}_{test}) berdimensi $n \times j$.
2. Mendefinisikan matriks data *output* (\mathbf{Y}_{test}) berdimensi $n \times 1$.
3. Bangkitkan nilai matriks bobot (\mathbf{w}) dan bias (\mathbf{b}), untuk nilainya berasal dari proses *training data*.
4. Pada langkah selanjutnya yaitu menghitung matriks inisialisasi dengan menggunakan persamaan berikut :

$$(\mathbf{H}_{init \ i,j}) = \sum_{k=1}^n w_{kj} \cdot x_{ik} + b_{1j}$$

dengan

$H_{init \ i,j}$ = matriks inisialisasi *testing*

5. Selanjutnya menghitung nilai fungsi aktivasi sigmoid dengan persamaan

$$\mathbf{H}_{test} = \frac{1}{1+\exp(-\mathbf{H}_{init})} \quad (2.25)$$

6. Langkah berikutnya menghitung hasil dari peramalan proses *testing* dengan rumus :

$$\hat{\mathbf{Y}}_{test} = \mathbf{H}_{test} \boldsymbol{\beta} \quad (2.26)$$

dimana

$\hat{\mathbf{Y}}_{test}$ = hasil peramalan pada proses *testing*

\mathbf{H}_{test} = *output hidden layer* pada proses *testing*

β = *output weight* dari proses *training*

- Langkah berikutnya melakukan denormalisasi dengan tujuan dapat mengembalikan nilai semula setelah di normalisasi pada tahap sebelum dilakukan proses *training data*.
- Menghitung nilai kesalahan *error* untuk melihat seberapa akurasi metode yang digunakan dengan nilai sebenarnya. Menghitung nilai kesalahan *error* menggunakan *Mean Absolute Percentage Error* (MAPE).

2.10 Matriks

Matriks adalah kumpulan bilangan-bilangan yang disusun secara khusus dalam bentuk baris dan kolom sehingga membentuk empat persegi panjang atau bujur sangkar yang ditulis diantara dua tanda kurung yaitu () atau []. Matriks tersebut dapat dinyatakan dalam bentuk :

$$\mathbf{A}_{m \times n} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1j} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2j} & \cdots & a_{2n} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{i1} & a_{i2} & \cdots & a_{ij} & \cdots & a_{in} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mj} & \cdots & a_{mn} \end{bmatrix}$$

Matriks juga dapat dinyatakan sebagai $\mathbf{A}_{m \times n} = [a_{ij}]_{m \times n}$.

Matriks adalah sekumpulan informasi yang umumnya berupa data numerik tersusun oleh baris dan kolom yang dibatasi oleh kurung sehingga membentuk sebuah jajaran persegi panjang. Matriks memiliki beberapa perhitungan yang disebut operasi pada matriks. Contoh dari operasi matriks yaitu matriks *transpose* dan matriks *Inverse*. Misalkan \mathbf{A} adalah sebuah matriks yang memiliki orde $n \times m$. Matriks *transpose* dari \mathbf{A} dapat dinotasikan \mathbf{A}^T .

1) Matriks *transpose*

Menurut Anton dan Rorres (1994), jika \mathbf{A} adalah matriks $m \times n$ maka *transpose* dari \mathbf{A} dinyatakan dengan \mathbf{A}^T , didefinisikan sebagai matriks $m \times n$ yang didapatkan dengan menukarkan baris-baris dan kolom-kolom dari \mathbf{A} ; sehingga kolom pertama dari \mathbf{A}^T adalah baris pertama dari \mathbf{A} , kolom kedua dari \mathbf{A}^T adalah baris kedua dari \mathbf{A} , dan seterusnya. Sifat-sifat *transpose* matriks sebagai berikut :

- $(\mathbf{A}^T)^T = \mathbf{A}$
- $(\mathbf{A} \pm \mathbf{B})^T = \mathbf{A}^T \pm \mathbf{B}^T$

$$c) (\mathbf{ABC})^T = \mathbf{C}^T \mathbf{B}^T \mathbf{A}^T$$

2) *Inverse* matriks

Menurut Anton dan Rorres (1994), jika \mathbf{A} adalah matriks bujursangkar, dan jika terdapat matriks \mathbf{B} yang ukurannya sama sedemikian sehingga $\mathbf{AB} = \mathbf{BA} = \mathbf{I}$, maka \mathbf{A} disebut *invertible* (dapat dibalik) dan \mathbf{B} disebut sebagai *Inverse* dari \mathbf{A} . Jika matriks \mathbf{B} tidak dapat didefinisikan, maka \mathbf{A} dinyatakan sebagai matriks *singular*. Terkadang, dapat ditemui matriks yang bukan bujursangkar. Kondisi ini apabila matriks \mathbf{A} merupakan matriks *non singular*, sehingga dapat dihitung dengan menggunakan matriks *Moore-Penrose generalized Inverse*.

2.11 *Moore-Penrose Generalized Inverse*

Pemecahan dari sistem linear umum $Ax = b$, ketika A matriks singular dan bukan persegi dapat diselesaikan dengan menggunakan *Moore-Penrose Generalized Inverse*.

Definisi 2.1 Diberikan matriks $A \in R_{m \times n}$. Terdapat matriks *unique* $A^+ \in R_{m \times n}$ yang dinamakan *Moore-Penrose Generalized Inverse* dari matriks jika memenuhi :

- i. $AA^+A = A$
- ii. $A^+AA^+ = A^+$
- iii. $(AA^+)^T = AA^+$
- iv. $(A^+A)^T = A^+A$ (Macausland, 2014)

Berikut ini adalah langkah-langkah mencari *moore-penrose generalized inverse*. yaitu:

1. Mereduksi matriks A menjadi matriks eselon baris tereduksi dan memisalkan matriks baru tersebut dengan matriks Y .
2. Melihat kolom yang memuat satu utama dari matriks Y dan pilih kolom tersebut dari matriks A , misalkan matriks baru tersebut adalah matriks F dan tentukan $F^T, (F^T F)^{-1}$.
3. Memilih baris yang tak nol dari matriks Y dan misalkan matriks G , tentukan dan $(GG^T)^{-1}$.
4. Mencari $A^+ = G^T(GG^T)^{-1}(F^T F)^{-1}F^T$

Berikut ini diberikan contoh untuk menentukan *Inverse moore penrose* dari suatu matriks berdasarkan langkah-langkah tersebut.

Contoh : Diberikan matriks $A = \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix}$. Tentukan *moore-penrose generalized Inverse* matriks .

Penyelesaian:

Diketahui matriks $A = \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix}$ Berikut ini langkah-langkah yang

dilakukan untuk memperoleh *moore-penrose generalized inverse* yaitu

1. Matriks yang terbentuk yaitu $Y = \begin{bmatrix} 1 & 0 & 2 \\ 0 & 1 & -\frac{3}{2} \\ 0 & 0 & 0 \end{bmatrix}$

2. Matriks yang terbentuk adalah sebagai berikut :

$$F = \begin{bmatrix} 0 & -2 \\ 3 & 6 \\ 6 & 6 \end{bmatrix}, F^T = \begin{bmatrix} 0 & 3 & 6 \\ -2 & 6 & 6 \end{bmatrix},$$

$$F^T F = \begin{bmatrix} 45 & 54 \\ 54 & 76 \end{bmatrix}, (F^T F)^{-1} = \begin{bmatrix} \frac{19}{126} & -\frac{3}{28} \\ -\frac{3}{28} & \frac{5}{56} \end{bmatrix}$$

3. Matriks G yang diperoleh yaitu

$$G = \begin{bmatrix} 1 & 0 & 2 \\ 0 & 1 & -\frac{3}{2} \end{bmatrix}, G^T = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 2 & -\frac{3}{2} \end{bmatrix},$$

$$G G^T = \begin{bmatrix} 5 & -3 \\ -3 & \frac{13}{4} \end{bmatrix}, (G G^T)^{-1} = \begin{bmatrix} \frac{13}{29} & \frac{12}{29} \\ \frac{12}{29} & \frac{20}{29} \end{bmatrix}$$

4. Matriks A^+ yang diperoleh yaitu

$$A^+ = G^T (G G^T)^{-1} (F^T F)^{-1} F^T$$

$$A^+ = \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ -\frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix}$$

Selanjutnya akan ditunjukkan bahwa A^+ *moore-penrose generalized* dengan mengecek bahwa A^+ memenuhi keempat persamaan *Penrose* yaitu :

i. $AA^+A = A$

$$\begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} = \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix}$$

$$\begin{bmatrix} \frac{5}{14} & -\frac{3}{7} & \frac{3}{14} \\ \frac{3}{7} & \frac{5}{7} & \frac{1}{7} \\ \frac{3}{14} & \frac{1}{7} & \frac{3}{14} \end{bmatrix} \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} = \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix}$$

$$\begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} = \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix}$$

Berdasarkan perhitungan diatas, jelas bahwa sifat (i) terpenuhi.

ii. $A^+AA^+ = A^+$

$$\begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} = \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix}$$

$$\begin{bmatrix} \frac{13}{29} & \frac{12}{29} & \frac{8}{29} \\ \frac{12}{29} & \frac{20}{29} & -\frac{6}{29} \\ \frac{8}{29} & -\frac{6}{29} & \frac{25}{29} \end{bmatrix} \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} = \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix}$$

$$\begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} = \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix}$$

Berdasarkan perhitungan diatas, jelas bahwa sifat (ii) terpenuhi.

iii. $(AA^+)^T = AA^+$

$$\left(\begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} \right)^T = \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix}$$

$$\left(\begin{bmatrix} \frac{5}{14} & -\frac{3}{7} & \frac{3}{14} \\ \frac{3}{7} & \frac{5}{7} & \frac{1}{7} \\ \frac{3}{14} & \frac{1}{7} & \frac{3}{14} \end{bmatrix} \right)^T = \begin{bmatrix} \frac{5}{14} & -\frac{3}{7} & \frac{3}{14} \\ \frac{3}{7} & \frac{5}{7} & \frac{1}{7} \\ \frac{3}{14} & \frac{1}{7} & \frac{3}{14} \end{bmatrix}$$

$$\begin{bmatrix} \frac{5}{14} & -\frac{3}{7} & \frac{3}{14} \\ \frac{3}{7} & \frac{5}{7} & \frac{1}{7} \\ \frac{3}{14} & \frac{1}{7} & \frac{3}{14} \end{bmatrix} = \begin{bmatrix} \frac{5}{14} & -\frac{3}{7} & \frac{3}{14} \\ \frac{3}{7} & \frac{5}{7} & \frac{1}{7} \\ \frac{3}{14} & \frac{1}{7} & \frac{3}{14} \end{bmatrix}$$

Berdasarkan perhitungan diatas, jelas bahwa sifat (iii) terpenuhi.

iv. $(A^+A)^T = A^+A$

$$\left(\begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix} \right)^T = \begin{bmatrix} \frac{9}{406} & \frac{2}{609} & \frac{89}{1218} \\ \frac{1}{29} & \frac{2}{29} & \frac{1}{29} \\ \frac{39}{406} & -\frac{59}{609} & \frac{115}{1218} \end{bmatrix} \begin{bmatrix} 0 & -2 & 3 \\ 3 & 6 & -3 \\ 6 & 6 & 3 \end{bmatrix}$$

$$\begin{bmatrix} \frac{13}{29} & \frac{12}{29} & \frac{8}{29} \\ \frac{12}{29} & \frac{20}{29} & -\frac{6}{29} \\ \frac{8}{29} & -\frac{6}{29} & \frac{25}{29} \end{bmatrix} = \begin{bmatrix} \frac{13}{29} & \frac{12}{29} & \frac{8}{29} \\ \frac{12}{29} & \frac{20}{29} & -\frac{6}{29} \\ \frac{8}{29} & -\frac{6}{29} & \frac{25}{29} \end{bmatrix}$$

Berdasarkan perhitungan diatas, jelas bahwa sifat (iv) terpenuhi.

Teorema 2.1 Jika A matriks singular dan bukan matriks persegi maka $(A^T A)^{-1} A^T$ merupakan *Moore Penrose Generalized Invers*.

(Macausland, 2014)

Bukti :

untuk membuktikan bahwa $(A^T A)^{-1} A^T$ merupakan *Moore Penrose Generalized Invers*, maka harus dibuktikan bahwa $(A^T A)^{-1} A^T$ memenuhi keempat sifat seperti pada Definisi 2.1. Misalkan $A^+ = (A^T A)^{-1} A^T$, dibuktikan A^+ memenuhi keempat sifat pada Definisi 2.1.

i. $AA^+A = A$

$$\begin{aligned} A((A^T A)^{-1} A^T)A &= A(A^T A)^{-1} A^T A \\ &= A(A^T A)^{-1} (A^T A) \\ &= AI = A \end{aligned}$$

$$\text{ii. } A^+AA^+ = A^+$$

$$\begin{aligned} ((A^T A)^{-1} A^T)A((A^T A)^{-1} A^T) &= (A^T A)^{-1}(A^T A)((A^T A)^{-1} A^T) \\ &= I((A^T A)^{-1} A^T) \\ &= (A^T A)^{-1} A^T \\ &= A^+ \end{aligned}$$

$$\text{iii. } (AA^+)^T = AA^+$$

$$\begin{aligned} (A((A^T A)^{-1} A^T))^T &= ((A^T A)^{-1} A^T)^T A^T \\ &= A((A^T A)^{-1} A^T) \\ &= AA^+ \end{aligned}$$

$$\text{iv. } (A^+A)^T = A^+A$$

$$\begin{aligned} ((A^T (AA^T)^{-1})A)^T &= A^T (A^T (AA^T)^{-1})^T \\ &= A^T (AA^T)^{-1} A \\ &= (A^T (AA^T)^{-1})A \\ &= A^+A \end{aligned}$$

Karena $(A^T A)^{-1} A^T$ memenuhi keempat sifat *Moore Penrose Generalized Invers*, maka terbukti bahwa A^+ adalah *Moore Penrose Generalized Invers*.

2.12 Minimum Norm Least-Square dari Bentuk Umum Sistem Linear

Untuk bentuk umum dari sistem linear $Ax = y$, kita dapat mengatakan \hat{x} adalah solusi kuadrat terkecil (*least square*) jika :

$$\|A\hat{x} - y\| = \min_x \|Ax - y\|$$

dengan $\|\cdot\|$ adalah norm pada ruang Euclid.

(Huang, 2006)

Definisi 2.2 $x_0 \in R^n$ dikatakan solusi minimum *least square* dari sistem linear $Ax = y$ jika setiap $y \in R^m$

$$\|x_0\| \leq \|x\|$$

$$\forall x \in \|Ax_0 - y\| \leq \|Ax - y\|, \forall x \in R^n$$

(Huang, 2006)

Artinya sebuah solusi x_0 dikatakan solusi *minimum least square* terkecil dari sistem linear $Ax = y$ jika x_0 terkecil diantara semua solusi kuadrat terkecil.

Teorema 2.2 Terdapat G sedemikian sehingga Gy adalah *minimum norm least square* dari sistem linear $Ax = y$, sehingga $G = A^+$ adalah syarat cukup dan perlu, *Moore Penrose Generalized Invers* dari mariks A .

Bukti :

Karena $G = A^+$ adalah syarat cukup dan perlu maka harus dibuktikan dua arah

- a. Jika Gy adalah *minimum norm least square* dari sistem linear $Ax = y$ maka $G = A^+$ adalah *Moore Penrose Generalized Invers* dari mariks A .

Karena Gy adalah *minimum norm least square* dari sistem linear $Ax = y$ sehingga

$$x = Gy \quad (2.27)$$

Jika A adalah mariks persegi, maka solusi dari $Ax = y$ adalah

$$x = A^{-1}y \quad (2.28)$$

karena sifat dari invers adalah tunggal, maka berdasarkan persamaan (2.27) dan (2.28) maka

$$G = A^{-1}$$

Jika bukan mariks persegi, maka solusi dari $Ax = y$ adalah

$$\begin{aligned} Ax &= y \\ A^T Ax &= A^T y \\ x &= (A^T A)^{-1} A^T y \end{aligned} \quad (2.29)$$

berdasarkan persamaan (2.27) dan (2.29) maka

$$G = (A^T A)^{-1} A^T$$

berdasarkan Teorema 2.1 $G = A^+$ adalah *Moore Penrose Generalized Invers*.

- b. Jika $G = A^+$ adalah *Moore Penrose Generalized Invers* dari mariks A , maka Gy adalah *minimum norm least square* dari sistem linear $Ax = y$. Berdasarkan Definisi 2.1 dan Teorema 2.1 $G = A^+$ adalah *Moore Penrose Generalized Invers* merupakan penyelesaian dari $Ax = y$.

2.13 Pemilihan Model Terbaik

Dalam penelitian ini pemilihan model terbaik dilihat berdasarkan nilai *Mean Absolute Percentage Error* (MAPE). MAPE merupakan nilai tengah kesalahan persentase *absolute*, jadi pada MAPE nilai positif atau negatif *error* tidak dihiraukan (Izati, 2019). Nilai MAPE dapat dihitung menggunakan rumus sebagai berikut :

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \times 100\% \quad (2.30)$$

dengan :

Y_t = Data sebenarnya periode t

\hat{Y}_t = Data peramalan periode t

n = Ukuran pengamatan

Semakin kecil nilai MAPE menunjukkan bahwa persentase kesalahan yang dihasilkan oleh model juga semakin kecil. Menurut Chang (2006), nilai evaluasi yang dihasilkan mempunyai kriteria MAPE seperti berikut:

- a. $MAPE < 10\%$: kemampuan peramalan sangat baik
- b. $10\% \leq MAPE < 20\%$: kemampuan peramalan baik
- c. $20\% \leq MAPE < 50\%$: kemampuan peramalan cukup
- d. $MAPE \geq 50\%$: kemampuan peramalan buruk

4.14 Pengujian Model

Pengujian model dilakukan untuk mengetahui parameter seperti apa yang menghasilkan *error* yang terkecil. Pada penelitian ini, pengujian model meliputi:

4.14.1 Pengujian fungsi aktivasi dan jumlah *neuron hidden layer*

Pengujian ini dilakukan untuk mengetahui fungsi aktivasi dan jumlah *neuron hidden layer* yang dapat memberikan performa ELM terbaik.

4.14.2 Pengujian kombinasi jumlah *neuron input* dan variasi jumlah data

Pengujian ini dilakukan untuk mengetahui kombinasi jumlah *neuron* pada *layer input* yang dapat memberikan hasil terbaik untuk setiap variasi data yang akan digunakan.