# PERAMALAN KONSUMSI LISTRIK DI DAERAH BALIKPAPAN MENGGUNAKAN METODE *EXTREME LEARNING MACHINE*

**SKRIPSI**

UIN SUNAN AMPEL
S U R A B A Y A

**Disusun Oleh:**

**ELITA MEGA TIANA**

**H76216033**

**PROGRAM STUDI SISTEM INFORMASI**
**FAKULTAS SAINS DAN TEKNOLOGI**
**UNIVERSITAS ISLAM NEGERI SUNAN AMPEL**
**SURABAYA**
**2020**

# PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : ELITA MEGA TIANA

NIM : H76216033

Program Studi : Sistem Informasi

Angkatan : 2016

Menyatakan bahwa sata tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul : "PERAMALAN KONSUMSI LISTRIK DI DAERAH BALIKPAPAN MENGGUNAKAN METODE *EXTREME LEARNING MACHINE*". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 27 Juli 2020

Yang menyatakan,

(Elita Mega Tiana)

NIM : H76216033

# LEMBAR PERSETUJUAN PEMBIMBING

Skripsi Oleh:

NAMA : ELITA MEGA TIANA

NIM : H76216033

JUDUL : PERAMALAN KONSUMSI LISTRIK DI DAERAH BALIKPAPAN MENGGUNAKAN METODE *EXTREME LEARNING MACHINE*

Ini telah diperiksa dan disetujui untuk diujikan.

Surabaya, 27 Juli 2020

Menyetujui,

| Dosen Pembimbing I | Dosen Pembimbing II |
|---|---|
| (Faris Muslihul Amin, M.Kom) | (Ahmad Yusuf, M. Kom) |
| NIP.198808132014031001 | NIP. 199001202014031003 |

# PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi Elita Mega Tiana ini telah dipertahankan

di depan tim penguji skripsi

di Surabaya, 27 Juli 2020

Mengesahkan,

Dewan Penguji

| | |
|---|---|
| Dosen Penguji I | Dosen Penguji II |
| (Faris Muslihul Amin, M.Kom) | (Ahmad Yusuf, M. Kom) |
| NIP.198808132014031001 | NIP. 199001202014031003 |
| Dosen Penguji III | Dosen Penguji IV |
| (Mujib Ridwan, S. Kom., M.T) | (Khalid, M.Kom) |
| NIP.198604272014031004 | NIP. 197906092014031002 |

Mengetahui

Plt. Dekan Fakultas Sains dan Teknologi

UIN Sunan Ampel Surabaya

(Dr. Evi Fatimatur Rusydiyah, M. Ag)

NIP. 197312272005012003

# LEMBAR PERSETUJUAN PUBLIKASI

**KEMENTERIAN AGAMA**
**UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA**
**PERPUSTAKAAN**
Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : ELITA MEGA TIANA
NIM : H76216033
Fakultas/Jurusan : FAKULTAS SAINS DAN TEKNOLOGI/SISTEM INFORMASI
E-mail address : elitatiana6@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :
■ Skripsi ☐ Tesis ☐ Desertasi ☐ Lain-lain (……)
yang berjudul :

PERAMALAN KONSUMSI LISTRIK DI DAERAH BALIKPAPAN

MENGGUNAKAN METODE *EXTREME LEARNING MACHINE*

Beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Ekslusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara ***fulltext*** untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 27 Juli 2020

Penulis

(ELITA MEGA TIANA)

# ABSTRAK

**PERAMALAN KONSUMSI LISTRIK DI DAERAH BALIKPAPAN UTARA DENGAN MENGGUNAKAN METODE *EXTREME LEARNING MACHINE***

**Oleh :**

**Elita Mega Tiana**

Penggunaan listrik seiring berkembangnya zaman meningkat sejalan dengan kenaikan listrik di setiap waktu, sehingga dalam penyediaan tenaga listrik yang digunakan disediakan dengan tepat agar listrik untuk konsumen bisa terpenuhi tanpa adanya hambatan. penelitian ini bertujuan untuk membuat model peramalan dengan bantuan metode jaringan syaraf tiruan *extreme learning machine*. ELM mampu mengatasi masalah dalam proses pembelajarannya yaitu proses pembelajarnya yang cepat dapat menghasilkan nilai akurasi yang kecil dalam pengujian *MSEnya.* Data diperoleh dari data historis di PLN Balikpapan. Data *inputan* berupa data kelompok pelanggan PLN yaitu kategori Rumah Tangga Kecil, dan Rumah Tangga Medium (2011-2019) dengan jumlah pelanggan 1000. Data tersebut di bagi menjadi 2 bagian yaitu data latih dan data uji. Menghasilkan nilai *MSE* sebesar 0,03313 dengan kecepatan *training* 9,72 detik di percobaan *hidden layer* ke *6.* Pengujian untuk membandingkan data aktual dengan data hasil peramalan, mendapatkan nilai akurasi *MAPE* 7.79% dimana untuk nilai kriteria *MAPE* kurang dari 10% merupakan kriteria peramalan yang sangat baik. diharapkan penelitian ini dapat memberikan masukan dalam peramalan kepada PLN tentang peningkatan konsumsi listrik pelanggan di masa mendatang.

**Kata Kunci *:*** *listrik¸ peramalan, ELM*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# *ABSTRACT*

## *FORCASTING ELECTRICAL CONSUMPTION IN NORTH BALIKPAPAN AREA USING THE EXTREME LEARNING MACHINE METHOD*

***By:***

***Elita Mega Tiana***

*The use of electricity in line with the development of the times increases with the increase in electricity at any time, so that the supply of electricity used is provided appropriately so that electricity for consumers can be fulfilled without any obstacles. This study aims to create a forecasting model with the help of the extreme learning machine artificial neural network method. ELM is able to overcome problems in the learning process, namely the fast learning process can produce small accuracy values in testing its MSE. Data obtained from historical data at PLN Balikpapan. Input data is in the form of data from PLN customer groups, namely the category of Small Households and Medium Households (2011-2019) with 1000 customers. The data is divided into 2 parts, namely training data and test data. Producing an MSE value of 0.03313 with a training speed of 9.72 seconds in the 6th hidden layer experiment. Testing to compare actual data with forecasted data, getting a MAPE accuracy value of 7.79% where for the MAPE criterion value less than 10% is a predictive criterion very good. It is hoped that this research can provide input in forecasting to PLN about the increase in electricity consumption of customers in the future.*

**Keywords*:*** *electricity¸ forecasting, ELM*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# DAFTAR ISI

**PENGESAHAN TIM PENGUJI SKRIPSI** ..... ii
**PERNYATAAN KEASLIAN** ..... iii
**LEMBAR PERSETUJUAN PUBLIKASI** ..... iv
**ABSTRAK** ..... v
***ABSTRACT*** ..... *vi*
**DAFTAR ISI** ..... vii
**DAFTAR GAMBAR** ..... ix
**DAFTAR TABEL** ..... x
**BAB I PENDAHULUAN** ..... 1
1.1. Latar Belakang ..... 1
1.2. Perumusan Masalah ..... 3
1.3. Batasan Masalah ..... 3
1.4. Tujuan Penelitian ..... 4
1.5. Manfaat Penelitian ..... 4
1.6. Sistematika Penulisan ..... 5
**BAB II KAJIAN PUSTAKA** ..... 6
2.1. Penelitian Terdahulu ..... 6
2.2. Teori Dasar ..... 9
2.2.1. Konsumsi Listrik ..... 9
2.2.2. Dasar Hukum Peraturan Tentang Usaha Penyediaan Tenaga Listrik ..... 10
2.2.3. Data Mining ..... 10
2.2.4. Peramalan ..... 12
*2.2.5. Time Series* ..... 13
2.2.7. Jaringan Saraf Tiruan ..... 14
*2.2.9. Denormalisasi* ..... 16
2.2.10. Metode Extreme Learning Machine ..... 17
*2.2.15.* Ukuran Kesalahan dengan *MSE (Mean Squared Error)* ..... 22



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*2.2.17.Python* ..... 23

2.3. Integrasi Keislaman ..... 23

**BAB III METODOLOGI PENELITIAN** ..... 26

3.1. Alur Penelitian ..... 26

3.1.1. Perumusan Masalah ..... 26

3.1.2. Studi Literatur ..... 27

3.1.3. Pengumpulan Data ..... 27

3.1.4. Pengelolahan Data ..... 28

3.1.5. Variabel Penelitian ..... 32

3.1.6. Lokasi dan Objek Penelitian ..... 33

**BAB IV PEMBAHASAN** ..... 34

4.1. Hasil Pengumpulan Data ..... 34

4.2. Pengolahan Data ..... 37

4.3. Preproscessing ..... 37

4.3.1. Tranformasi data ke bentuk *Time Series* ..... 37

4.3.2. Normalisasi Data ..... 39

4.4. Perhitungan ELM untuk peramalan konsumsi listrik ..... 41

4.4.1. Prosedur Training Data ..... 42

4.4.2. Prosedur Testing data ..... 45

4.4.3. Pengujian Akurasi ..... 48

4.4.5. Denormalisasi ..... 49

*4.5.* Hasil dan Analisis Peramalan Konsumsi Listrik Menggunakan Metode *Extreme Learning Machine.* ..... 49

4.6. Evaluasi Hasil Pengujian ..... 50

**BAB V PENUTUP** ..... 54

5.1. Kesimpulan ..... 54

5.2. Saran ..... 54

**DAFTAR PUSTAKA** ..... 55



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# DAFTAR GAMBAR

Gambar 2. 1 Jaringan Lapisan Tunggal (Schikuta, 2008)..... 15

Gambar 2. 2 Jaringan Multilayer (Schikuta, 2008)..... 15

Gambar 2. 3 Jaringan lapisan kompetitif (Schikuta, 2008)..... 16

Gambar 2. 4 Struktur ELM (Prakoso, Wisesty and ., 2016) ..... 20

Gambar 3. 1 Flowchart Model Penelitian.....26

Gambar 3. 2 Flowchart Metode ELM ..... 28

Gambar 3. 3 Flowchart Training data ..... 29

Gambar 3. 4 Flowchart Testing data ..... 31

Gambar 4. 1 plot time series data pelanggan pemakaian listrik.....35

Gambar 4. 2 Hasil Boxplot Outlier panjang 200 – 700 ..... 36

Gambar 4. 3 Hasil Boxplot Outlier panjan 600 – 1200 ..... 36

Gambar 4. 4 Hasil Boxplot panjang 100 – 700..... 37

Gambar 4. 5 plot grafik hasil proses testing data aktual dan data hasil ..... 53



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu ..... 6

Tabel 2. 2 Kriteria MAPE ..... 23

Tabel 3. 1 Rancangan data untuk normalisasi .....28

Tabel 3. 2 Variabel Input ..... 32

Tabel 4. 1 Kutipan Rancangan Pemakaian Konsumsi Pelanggan R1.....34

Tabel 4. 2 Kutipan Rancangan Pemakaian Konsumsi Pelanggan R1M ..... 35

Tabel 4. 3 Tabel Time Series pelanggan R1 ..... 38

Tabel 4. 4 Hasil time series per pelanggan ..... 39

Tabel 4. 5 Function Normalisasi ..... 40

Tabel 4. 6 Hasil Normalisasi data training Pelanggan R1 ..... 40

Tabel 4. 7 Hasil Normalisasi data pelanggan R1M..... 41

Tabel 4. 8 Library yang digunakan ..... 41

Tabel 4. 9 Tabel Alur Training ..... 43

Tabel 4. 10 Function untuk training data ..... 43

Tabel 4. 11 Proses Testing data ..... 46

Tabel 4. 12 Function Testing Data..... 46

Tabel 4. 13 Proses Pengujian MSE..... 48

Tabel 4. 14 Function uji MSE..... 48

Tabel 4. 15 Function Denormalisasi data..... 49

Tabel 4. 16 Hasil prediksi listrik Pelanggan R1 menurut MSE ..... 49

Tabel 4. 17 Hasil peramalan konsumsi listrik dengan metode ELM ..... 51

Tabel 4. 18 Hasil Perhitungan akurasi data asli dan data ramalan..... 51



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# BAB I
# PENDAHULUAN

## 1.1. Latar Belakang

Kebutuhan energi listrik memegang peran yang besar dalam kehidupan, manfaat yang didapatkan tidak hanya berguna di masa kini tetapi juga berguna untuk masa depan (Hadijah, 2014). Listrik dikatakan kebutuhan yang sangat mendasar dalam kehidupan dan menjadi hal yang sangat penting dalam pertumbuhan perekonomian. Tanpa adanya listrik maka kehidupan di zaman yang modern ini akan terhambat. Oleh karena itu listrik menjadi hal yang sangat penting untuk kebutuhan sehari-hari (Nababan, 2008). Semakin pesatnya berkembangan teknologi industri, dll, maka konsumsi listrik akan semakin meningkat, dalam penggunaan listrik terus menerus akan mengalami kenaikan yang jumlahnya tidak bisa ditentukan secara menentu atau pasti, oleh sebab itu listrik sebagai bagian yang terpenting dalam kemajuan peradaban manusia baik dari bidang ekonomi, dll (Indonesia *et al.*, 2012).

Permintaan kebutuhan energi listrik yang tidak diimbangi dengan suplai energi listrik yang memadai maka akan berdampak pada kurangnya penyediaan listrik. Hal tersebut dapat mengganggu aktivitas perekonomian yang menyebabkan sektor pengguna tidak tercukupi dengan optimal (Aji, 2010). Energi listrik tidak bisa di simpan dalam sekala yang besar, melainkan disediakan dalam waktu yang dibutuhkan. Oleh karena itu timbullah persoalan untuk menghadapi permasalahan tentang kebutuhan daya listrik yang terus menerus mengalami peningkatan, lalu bagaimana cara dalam menyediakan atau mengoperasikan energi listrik yang dapat memenuhi kebutuhan pada setiap saat dengan kualitas yang baik. permasalahan yang ditimbulkan adalah apabila energi listrik yang di distribusikan dari pembangkit jumlahnya lebih besar dari permintaan yang diinginkan pada beban listrik, maka akan menyebabkan masalah membuang-buang energi untuk perusahaan listik. Dalam artian dapat mengakibatkan kerugian bagi penyedia tenaga listrik yakni PT. PLN (Persero), hal tersebut dapat menimbulkan kerusakan pada instalasi energi listrik. Sedangkan untuk daya energi listrik yang dibangkitkan dan dikirimkan lebih rendah dan tidak mencukupi untuk pemenuhan kebutuhan maka masalah yang terjadi adalah penuruan frekuensi instalasi yang dapat mengakibatkan pemadaman lokal yang merugikan pihak konsumen (Muslimin,



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

2015). Untuk itu diperlukannya penyesuaian antara pembangkit dan permintaan yang dibutuhkan untuk stabilitas energi listrik.

Maka dari itu diperlukannya usaha meramalkan permintaan konsumen dalam pemenuhan listrik yang nantinya mampu dalam hal operasi sistem tenaga listrik dan ekonomi. Jika permintaan listrik yang diramalkan besar maka berpengaruh dalam kesiagaan pembangkit untuk penyediaan cadangan energi listrik konsumen.

Peramalan dibagi menjadi beberapa waktu, pada penelitian ini waktu yang digunakan adalah jangka menengah yaitu peramalan daya listrik untuk rentang waktu bulanan sampai waktu setahun yang dapat digunakan untuk merencanakan dalam memperluas jaringan dan pembangkit listrik baru. Peramalan rentang waktu menengah dapat digunakan dalam menghitung berapa aliran daya yang dibutuhkan dan dapat digunakan untuk mencegah kejadian pembebanan yang berlebihan (Muslimin, 2015). Dilihat dari situs CNN Indonesia bahwa Pada tahun 2019 Presiden Joko Widodo mengumumkan bahwa provinsi Kalimantan Timur secara resmi menjadi Ibu Kota baru atau pusat pemerintahan kedua setelah mempertimbangkan beberapa hal yang membuat Provinsi Kalimantan Timur cocok untuk dijadikan Ibu Kota Baru. Salah satunya daerah Balikpapan yang letaknya berada di provinsi Kalimantan Timur. Balikpapan dari segi kependudukan juga termasuk kota terbesar kedua setelah kota Samarinda. Jumlah penduduk pada tahun 2018 sebanyak 645.727 jiwa. Dalam hal tersebut maka peningkatan energi listrik di daerah Balikpapan akan mengalami peningkatan yang *signifikan.* Kepadatan penduduk dapat mempengaruhi permintaan konsumsi listrik yang digunakan. (Hadijah, 2014).

Peramalan dapat digunakan dengan menggunakan bermacam - macam metode seperti halnya menggunakan metode *neural network,* metode pembelajaran *backpropagation* (Sari, Mahmudy and Wibawa, 2016), *Support Vector Machine (SVM)* (F., Elsir and Faris, 2015), dan *extreme learning machine (ELM)* (Huang *et al.*, 2015). Banyak judul karya ilmiah yang terkait prediksi menggunakan metode *extreme learning machine* salah satunya yakni penelitian dengan judul "Jaringan syaraf tiruan ELM untuk memprediksi kondisi cuaca di malang" hasil dari penelitian itu adalah data pelatihan memperoleh nilai MSE minimum yaitu 0,064560051 jumlah *hidden nodenya 4* dengan jumlah iterasi ke 500, dan akhirnya



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

di proses testing menggunakan bobot dan bias optimal (Humaini, 2015). Maka dari itu penelitian ini melakukan peramalan menggunakan metode *Extreme learning machine (ELM)* (Huang *et al.*, 2015). ELM merupakan metode yang menggunakan konsep *single hidden layer feed forward networks (*SLFNs). ELM diciptakan untuk mengatasi beberapa kelemahan dari metode jaringan syaraf tiruan agar di dalam proses komputasi atau pembelajaran lebih cepat. ELM sendiri baik untuk digunakan untuk peramalan dalam waktu cepat, dan di aplikasikan pada masalah yang lebih canggih yang bisa diterapkan dalam kehidupan nyata (G. Huang, Zhu and Siew, 2004).

Berdasarkan penelitian yang sudah dilakukan menggunakan metode tersebut maka penelitian yang akan dilakukan selanjutnya adalah dengan judul "PERAMALAN KONSUMSI LISTRIK DI DAERAH BALIKPAPAN UTARA DENGAN METODE EXTREME LEARNING MACHINE". Dengan harapan hasil yang dapatkan dari penelitian ini mampu memberikan kontribusi masukan dalam perusahaan ketenagalistrikan untuk membantu merencanakan target konsumsi pemakaian konsumsi listrik di masa akan mendatang dengan hasil yang optimal.

## 1.2. Perumusan Masalah

Berdasarkan latar belakang yang sudah dijelaskan diatas, maka dapat dirumuskan beberapa permasalan yang akan dibahas dalam tugas akhir ini, berikut perumusan masalahnya:

1. Bagaimana menerapkan metode *Extreme Learning Machine* dalam peramalan konsumsi pemakaian listrik*?*
2. Bagaimana kinerja metode *Extreme Learning Machine* dalam meramalkan konsumsi pemakaian listrik ?

## 1.3. Batasan Masalah

Adapun beberapa ruang lingkup penelitian tugas akhir ini antara lain:

1. Data yang digunakan adalah data konsumsi pemakaian listrik pasca bayar di wilayah Balikpapan Utara.
2. Penelitian ini untuk meramalkan konsumsi listrik yang digunakan menggunakan data waktu perbulan.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

3. Data konsumsi pemakaian listrik yang digunakan dimulai dari data bulan Januari 2011 – Desember tahun 2019.
4. Tarif daya listrik yang digunakan hanya menggunakan tarif R1M (Rumah Tangga Medium) dan R1 (Rumah Tangga).

## 1.4. Tujuan Penelitian

1. Untuk mengetahui penerapan metode *Extreme Learning Machine* untuk meramalkan pemakaian konsumsi listrik.
2. Untuk mendapati hasil kinerja menggunakan metode *Extreme Learning Machine* dalam peramalan pemakaian konsumsi listrik.

## 1.5. Manfaat Penelitian

Manfaat penelitian dibagi menjadi beberapa berikut ini :

1. Manfaat Akademik
   a. Memanfaatkan metode *Extreme Learning Machine* untuk meramalkan konsusmi listrik di daerah Balikpapan Utara.
   b. Memberikan hasil peramalan untuk rekomendasi berdasarkan hasil pengolahan data.
   c. Sebagai referensi dari penelitian yang nantinya bisa dipelajari oleh pembaca.
   d. Menambahkan wawasan dan pengetahuan khususnya dalam menganalisis peramalan pemakaian listrik serta dapat mengetahui langkah – langkah menganalisis, mengetahui rumus-rumus dan cara menghitung dalam peramalan konsumsi listrik.
2. Manfaat Praktis
   a. Untuk Perusahaan diharapkan dapat membantu dalam menentukan metode peramalan yang tepat dalam perencanaan pemakaian konsumsi listrik untuk pelanggan rumah tangga yang akan mendatang dengan tepat dan juga optimal.
   b. Diharapkan dapat memberikan sumbangan pikiran terkait analisis peramalan konsumsi listrik dalam menetapkan perencanaan penyediaan daya listrik untuk pelanggan rumah tangga dan menjadi masukan untuk dipertimbangkan dalam mencapai tujuan.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

## 1.6. Sistematika Penulisan

Pada penulisan Tugas Akhir ini memiliki aturan dan sistematika yang dibagi atas beberapa bagian, sebagai berikut:

**BAB 1 PENDAHULUAN**

Pada Bab 1 pendahuluan menjelaskan latar belakang permasalahan yang dianggap diangkat pada penelitian, rumusan masalah, tujuan penelitian, batasan penelitian, manfaat yang diperoleh dari penelitian yang dibuat dan sistematika penyusunan tugas akhir.

**BAB 2 TINJAUAN PUSTAKA**,

Pada Bab 2 berisi penjelasan singkat tentang teori" yang terkait dengan penelitian ini, seperti konsep sistem informasi, metode *Extreme Learning Machine* dan berisi teori pendukung yang terkait dengan penelitian tugas akhir ini.

**BAB 3 METODOLOGI PENELITIAN**

Pada bab 3 metodologi penelitian berisi penjelasan atas alur penelitian dan terdiri dari beberapa tahap antara lain yaitu melakukan identifikasi terhadap kebutuhan, melakukan perencanaan, langkah-langkah penelitian, dan tahap implementasi.

**BAB 4 HASIL DAN PEMBAHASAN**

Pada bab 4 berisi penjelasan hasil, pengolahan data dalam menyelesaikan penelitian sesuai dengan alur yang dibahas oleh peneliti .

**BAB 5 PENUTUP**

Pada bab ini berisi kesimpulan dari rumusan masalah dan berisi saran dari penulis setelah mendapatkan hasil dari penelitian.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# BAB II
# KAJIAN PUSTAKA

## 2.1. Penelitian Terdahulu

Dalam proses penelitian ini diperlukan beberapa penelitian terdahulu guna untuk mendapatkan pemahaman dan referensi dengan upaya untuk mendapatkan informasi dan perbandingan dalam memperoleh inspirasi baru dalam penelitian selanjutnya. Pada bagian ini peneliti menjabarkan hasil penelitian terdahulu yang terkait dengan penelitian yang hendak dilakukan. Berikut ini adalah kajian yang mempunyai keterkaitan atau relasi dengan penelitian yang akan dilakukan:

**Tabel 2. 1** *Penelitian Terdahulu*

| No | Judul | Metode | Hasil |
|---|---|---|---|
| 1. | Penerapan Metode *Extreme Learning Machine* untuk peramalan perminataan (Agustina, Anggraeni and Mukhlason, 2005). | metode *Extreme Learning Machine* | Hasil yang di peroleh yaitu mendapatkan hasil kesalahan yang rendah yaitu dengan pengujian MAPE untuk kaos diperoleh nilai 0,0042% dan untuk produk pin diperoleh nilai 0,0095%. Dalam *training time* yang dibutuhkan dalam peramalan yaitu berkisar 0,0059 detik |
| 2. | Kinerja metode *extreme learning machine (ELM*) pada sistem peramalan (Khotimah, Sari R and Yulianarta, 2010) | metode *Extreme Learning Machine* | Hasil penelitian yang dilakukan mendapatkan nilai *error* kesalahan minimum menggunakan *Mean Square Error* menghasilkan nilai error paling kecil dengan nilai bobotnya kecil. |
| 3. | Prediksi Pemakaian Listrik Kelompok Tarif Menggunakan Jaringan Syaraf | Metode ARIMA dan jaringan saraf tiruan *Backproagation* | Untuk memprediksi permintaan listrik kategori sosial, rumah tangga, industri, di masa mendatang. Hasil erorr *MSE*nya memiliki nilai yang besar |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| | | | |
|---|---|---|---|
| | Tiruan dan ARIMA (Studi Kasus Wilayah Suluttenggo) (Rumagit and SN, 2013). | | kemudian diuji dengan gabungan ARIMA dan Jaringan Saraf tiruan nilainya tidak jauh berbeda dengan metode ARIMA. Setiap error yang dihasilkan berbeda tergantung data variabel yang dimasukkan. |
| 4. | *Analysis and Modeling for China's Electricity Demand Forecasting Using a Hybrid Method Based on Multiple Regression and Extreme Learning Machine: A View from Carbon Emission* (Liang *et al.*, 2016). | Metode *Hybrid based on multiple regression and extreme learning machine.* | Hasil peramalan permintaan listrik pada jangka menengah dan panjang dengan melihat prespektif rendah ekonomi karbon, mendapatkan model peramalan yang optimal dalam perencanaan daya, menghasilkan model peramalan kombinasi yang optimal pada model *Extreme Learning Machine* dan regresi ganda terdapat 3 sekenario yang sejalan dengan tingkat realisasi target ekonomi yaitu rendah karbon, dan simulasi efek rendah ekonomi karbon pada permintaan yang akan mendatang. |
| 5. | *Time Series* untuk Peramalan Konsumsi Listrik Menggunakan Metode *Support Vector Machine (SVM*) (Puspita, 2017). | Metode Support Vector Machine (SVM) | Hasil permintaan konsumsi listrik dengan data linier atau non linier dengan data time series yang menggunakan kernel Radial Basis Function (RBF) mampu mengatasi masalah overfitting yang dapat memecahkan masalah peramalan *Time Series* dan menghasilkan nilai MSE dan MAE kecil. |
| 6. | Peramalan konsumsi listrik berdasarkan | Metode ARIMA BOX-JENKINS | Hasil peramalan permintaan energi listrik berdasarkan pemakaian kwh kategori industri |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| | | | |
|---|---|---|---|
| | pemakaian kwh kategori industri I-4 di PT. PLN (Persero) distribusi jawa timur menggunakan *ARIMA BOX-JENKINS* (Bisnis and Vokasi, 2017) | | skala besar. Mendapatkan model konsumsi yang terbaik dalam pemakain Kwh kategori industri I-4 dengan model ARIMA ([1,8],1,0), dan nilai ramalan pemakaian Kwh meningkat sebesar 3,19%. |
| 7. | *Predicting residential electricity consumption using neural networks: A case study*. (Yoo and Myriam, 2018) | Metode *Neural Network* | Hasil prediksi dengan menggunakan beberapa variabel yang mempengaruhi konsumsi listrik rumah tangga di perumahan seoul tingkat kesalahan rata-ratanya sebesar 2,037% menggunakan jaringan saraf tiruan dan variabel yang mempengaruhi adalah populasi lansia karena populasi lansia lebih sering berada dirumah dan lebih banyak konsumsi listrik. |
| 8. | *Prediction of Short-Term Electricity Consumption by Artificial Neural Networks Using Temperature Variables* (Makalesi, Aydın and Toros, 2018). | Metode *Neural Network* | Hasil prediksi yang diperoleh dari pengaruh konsumsi listrik yang menambahkan variabel suhu di kota turki di 12 provinsi mendapatkan hasil kesalahan yang masuk akal, dan bisa direncanakan untuk model perkiraan masa akan datang. |
| 9. | Optimasi Bobot pada *Extreme* | Metode *Extreme Learning Machine* | Hasil penelitinya membangun sistem komputasi cerdas untuk |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| | | | |
|---|---|---|---|
| | *Learning Machine* untuk Prediksi Beban Listrik menggunakan Algoritme Genetika (Studi Kasus: PT. PLN (Persero) APD Kalsel dan Kalteng) (Meilia, Setiawan and Santoso, 2018). | dengan optimasi bobot menggunakan algoritme genetika. | mengetahui prediksi beban listrik yang dapat diterapkan untuk memprediksi beban listrik yang dapat memberikan hasil yang baik dengan rata-rata error MAPE yang optimasi bobotnya yakni bernilai 0.7996% kemudian untuk kesalahan MAPE tanpa menggunakan optimasi bobot menghasilkan 1.1807% dengan hal tersebut menghasilkan prediksi yang lebih baik. |

Dari penelitian terdahulu yang sudah disajikan pada ditabel 2.1 maka bisa disimpulkan metode *Extreme Learning Machine* banyak digunakan dalam penelitian peramalan akan tetapi berbeda – beda studi kasus, berdasarkan penelitian terdahulu dengan metode *Extreme Learnning Machine* yang sudah diimplementasikan memperoleh hasil yang optimal dalam peramalan. Nilai yang dihasilkan MSE nya kecil dibandingkan dengan metode - metode lain yang pernah digunakan. Untuk itu peneliti melakukan penelitian dengan menggabungkan antara latar belakang masalah yang dihadapi diatas dengan metode *Extreme Learning Machine* sehingga diperoleh judul yang akan diangkat yakni "Peramalan Konsumsi Listrik di Daerah Balikpapan Utara dengan Metode *Extreme L earning Machine.* Diharapkan penelitian yang dilakukan bisa mendapatkan hasil yang optimal.

## 2.2. Teori Dasar

### 2.2.1. Konsumsi Listrik

Konsumsi listrik adalah banyaknya listrik yang digunakan oleh kelompok listrik kategori rumah tangga yang dihitung selama sebulan. Konsumsi listrik diukur menggunakan jumlah KWH meter. KWH meter merupakan alat penghitung pemakian energi listrik. Sedikit banyak penggunaan konsumsi listrik rumah tangga tergantung pada masing-masing kebutuhan pelanggan. Konsumsi listrik dapat dihitung dengan mengkalikan hasil aktivitas jumlah pemakaian dan intensitas energi (Purnama, Setiawan and Suhanan, 2017)



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

### 2.2.2. Dasar Hukum Peraturan Tentang Usaha Penyediaan Tenaga Listrik

Menurut peraturan pemerintah tentang usaha penyediaan tenaga listrik menurut menteri ESDM No. 31 tahun 2014 dan no. 09 tahun 2015 bahwa terdapat 12 golongan tarif tenaga listrik disediakan PT. PLN (Persero) dinyatakan dalam tarif dasar listrik. Tarif dasar tersebut sudah diatur pemerintah untuk menetapkan tarif di seluruh Indonesia, Tarif dasar listrik tersebut terdiri atas:

1) Golongan Tarif untuk R-1/ TR (Rumah tangga kecil) dengan batas daya 0 – 450 VA
2) Golongan Tarif untuk R-1/ TR (Rumah tangga kecil) dengan batas daya 451 – 900 VA
3) Golongan Tarif untuk R-1M/ TR (Rumah tangga menengah) dengan batas daya 451– 900 VA
4) Golongan Tarif untuk R-2/ TR (Rumah tangga menengah) dengan batas daya 2201 VA - 5500 VA
5) Golongan Tarif untuk R-3/ TR (Rumah tangga besar) dengan batas daya >5501 VA
6) Golongan Tarif untuk B-1/ TR (Bisnis sedang) dengan batas daya 1301-5500 VA
7) Golongan Tarif untuk B-3/ TR (Bisnis besar ) dengan batas daya >200 kVA
8) Golongan Tarif untuk I-3/ TR (Industri skala menengah) dengan batas daya >200 kVA
9) Golongan Tarif untuk I-4/ TR (Industri besar) dengan batas daya >30.000 kVA
10) Golongan Tarif untuk P-1/ TR (Kantor pemerintahan kecil) dengan batas daya 5501 VA – 200 kVA
11) Golongan Tarif untuk P-2/ TR (Kantor pemerintahan besar) dengan batas daya > 200 kVA
12) Golongan Tarif untuk P-3/ TR untuk penerangan jalan umum (Kementerian ESDM, 2020).

### 2.2.3. Data Mining

Data Mining merupakan istilah yang dipakai untuk pengumpulan suatu informasi penting dalam sebuah database. Proses dalam mengolah Data Mining sering menggunakan metode matematika, kecerdasan buatan, statistika, dan



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*machine learning* untuk meringkas dan mengidentifikasi informasi pengetahuan yang berguna dan bermanfaat yang tersimpan di dalam database besar. Berikut ini data mining dibagi menjadi beberapa kelompok (Mardi, 2017):

a. *Description* (Deskripsi)

Arti kata deskripsi pada *data mining* adalah model pembelajaran yang digunakan untuk menggali pengetahuan karakteristik pola data. Proses deskripsi diharap bisa mengetahui kecenderungan yang terdapat dalam data. Dengan menggunakan deskripsi maka dapat dengan mudah menemukan pola yang tersembunyi dalam sebuah data yang digunakan. Seperti dalam proses pengumpulan suara presiden tidak menemukan fakta atau keterangan siapa yang tidak profesional dalam pemilihan presiden. Dari situ deskripsi dari pola dan kecenderungan sering memberikan kemungkinan penjelasan untuk suatu pola data .

b. *Estimation* (Estimasi)

Estimasi dalam *data mining* adalah memperkirakan banyak sediktinya nilai dalam sebuah data. Dalam proses estimasi hampir sama dengan klasifikasi, tetapi variabel target estimasi lebih ke arah numerik daripada ke arah kategori. Model estimasi dibangun dengan cara merekam yang lengkap yang dapat menyediakan nilai dari variabel target sebagai nilai prediksi. Contohnya adalah seperti dalam mengestimasi nilai IPK mahasiswa program sarjana strata dengan melihat nilai IPS (indeks prestasi mahasiswa) pada saat mengikuti program sarjana.

c. *Prediction* (Prediksi)

Prediksi dalam *data mining* adalah sebuah proses yang menemukan pola tertentu dari sebuah data, pola-pola tersebut diketahui dari berbagai variabel yang ada, ketika pola telah ditemukan maka bisa digunakan untuk memprediksi variabel lain yang belum diketahui. Dalam proses prediksi hampir sama dengan proses estimasi dan klasifikasi, kecuali dalam prediksi nilai dari hasil akan ada dimasa mendatang. Seperti contoh dalam memprediksi bisnis dan penelitian yaitu prediksi harga beras dalam enam bulan yang akan datang, prediksi tingkat pengagguran sepuluh tahun akan datang. Maka metode untuk prediksi bisa digunakan menggunakan teknik dalam klasifikasi, dan estimasi.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

d. *Classification* (Klasifikasi)

Klasifikasi dalam *data mining* adalah penyusunan dalam kelompok sesuai dengan ketentuan yang sudah ditentukan. Dalam proses klasifikasi terdapat target variabel kategori. Seperti dalam penggolongan pendapatan dapat dipisahkan dalam tiga kategori, yakni pendapatan tinggi, sedang dan rendah.

e. *Clustering* (Pengklusteran)

C*lustering* dalam *data mining* adalah mengelompokkan data dengan ciri khas dan karakteristik yang sama. Dalam proses pengklusteran yaitu mengelompokkan record, pengamatan, atau memperhatikan dan membentuk kelas objek-objek yang memiliki kemiripan. Cluster adalah kumpulan dataset yang memiliki kemiripan satu dengan yang lainnya dan memiliki ketidakmiripan dengan dataset-dataset dalam cluster lain. Seperti dalam mendapatkan nilai mana yang termasuk dalam penjualan yang paling banyak diminati dan mana yang tidak banyak di minati.

### 2.2.4. Peramalan

Peramalan (*forecasting)* adalah kegiatan untuk meramalkan berapa nilai dalam variabel berdasarkan nilai yang sudah diketahui dari variabel tersebut atau variabel yang terhubung (Yuwida, Hanafi and Wahyuningsih, 2012).

Peramalan dalam kehidupan sudah 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*. Dibawah ini merupakan beberapa jenis dalam peramalan listrik yakni (Jayanti, Cholissodin and Santoso, 2018) :

a. Peramalan jangka waktu sangat pendek adalah peramalan dalam 5 menit sampai 30 menit.
b. Peramalan rentang waktu pendek adalah peramalan dalam waktu kurang dari 30 bulan.
c. Peramalan rentang waktu menengah adalah peramalan yang dilakukan waktu 1 sampai 5 tahun



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

d. Peramalan rentang waktu yang panjang adalah peramalan dalam waktu lebih dari 5 tahun .

Kemajuan dalam ilmu pengetahuan mampu memberikan penjelasan yang teoritis, oleh karena itu peramalan tidak hanya dianggap sebagai dugaan tanpa landasan yang kuat (Rachman, Cholissodin and Fauzi, 2018).

### *2.2.5. Time Series*

Runtun waktu pertama kali diperkenalkan dan dikembangkan pada tahun 1970 oleh Box dan Jenkins (Bisnis and Vokasi, 2017). Runtun waktu merupakan penelitian dengan terurut dalam waktu atau dalam dimensi lain. Menurut sejarah nilai dalam penelitian menggunakan variabel runtun waktu dibedakan menjadi dua yaitu runtun waktu deterministik dan runtun waktu stokastik. Runtun waktu deterministik merupakan suatu runtun waktu dimana keadaan yang akan datang dapat diramalkan secara pasti dan tidak perlu penyelidikan kembali. Runtun waktu stokastik merupakan penelitian dengan menggunakan runtun waktu dimana menggunakan waktu yang akan datang dengan sifat probabilistik, menurut penelitian yang di masa lalu (Ruliah and Rolyadely, 2012)

### 2.2.6. *Machine Learning*

*Machine Learning* adalah suatu cabang berasal dari ilmu *Artificial Intelligence* yang fokusnya terdapat pada pembangunan sebuah sistem agar dapat belajar dari data-data yang diperoleh. Menurut salah satu ahli ilmuan Arthur Samuel, merupakan pelajaran yang dapat memberikan keterampilan dalam program komputer untuk belajar tanpa secara langsung di program. Agar bisa mengaplikasikan ke dalam *Machine Learning* harus adanya data jika tidak ada data maka algoritma *Machine Learning* tidak bisa berjalan. Data yang sudah ada kemudian dibagi menjadi dua yaitu data *training* dan data *testing.* Data latih merupakan data yang digunakan untuk melatih algoritma, kemudian data penguji merupakan data yang digunakan untuk melihat tampilan algoritma yang sudah dilatih sebelumnya pada data *training* pada saat menemukan data yang baru dan belum pernah dilihat sebelumnya (Fikriya *et al.*, 2017).



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

### 2.2.7. Jaringan Saraf Tiruan

Jaringan syaraf tiruan merupakan gambaran jaringan yang terbuat dari otak manusia yang disimulasikan proses pembelajarannya pada otak manusia. Pada istilah tersebut digunakan karena jaringan syaraf dapat diimplementasikan kedalam program komputer yang nantinya mampu dalam menyelesaikan proses perhitungan dalam proses pembelajaran (Sri Kusumadewi, 2003).

Jaringan saraf tiruan terdapat 3 lapisan yang terdiri dari lapisan unutuk *input*, lapisan untuk tersembunyi, dan lapisan untuk keluaran. Disetiap penghubung terdapat dua lapisan dengan isi bobot tertentu dan berisikan arah yang menunjukkan aliran data sendiri dalam sebuah proses. Untuk lapisan *input* mengisikan sebuah *input* parameter seperti penggunaan konsumsi listrik. Kemudian untuk lapisan tersembunyi berisikan lapisan yang menerima masukan dari lapisan *input* atau lapisan tersembunyi sebelumnya, lapisan ini berada di tengah, pada lapisan tersembunyi bertugas untuk mengkombinasikan semua masukan dari lapisan *input* berdasarkan bobot dari relasi yang terhubung dalam melakukan perhitungan, dan memberikan hasil keluaran untuk lapisan berikutnya. Sedangkan untuk lapisan keluaran menghasilkan keluaran dari jaringan yang telah disusun (Sri Kusumadewi, 2003)

#### 2.2.7.1. Arsitektur Jaringan Saraf Tiruan

Pada jaringan saraf tiruan terdiri dari beberapa neuron yang akan dijadikan satu dalam sebuh lapisan yang disebut dengan lapisan neuron (neuron layers). Neuron-neuron lainnya pada satu lapisan akan dihubungkan dengan lapisan-lapisan lainnya. Kemudian lapisan – lapisan tersebut menghasilkan sebuah informasi yang diperoleh dari neuron yang disampaikan ke semua lapisan-lapisan yang ada, yaitu dari lapisan masukan sampai dengan lapisan keluaran melalui lapisan tersembunyi (*hidden layer*). Jaringan saraf tiruan terdapat tiga lapisan, dan terdapat beberapa jaringan saraf ada yang tidak memiliki lapisan tersembunyi. Dibawah ini merupakan 3 jenis untuk arsitektur jaringan saraf tiruan yang terdiri dari (Sel, 1940):

a. Jaringan dengan lapisan tunggal (*Single layer net)*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

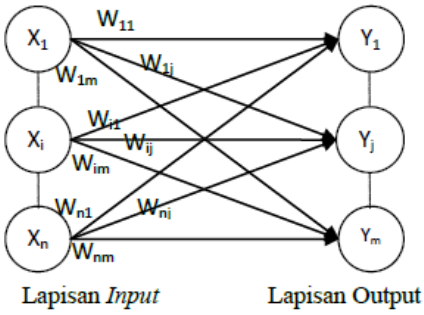


**Gambar 2. 1** *Jaringan Lapisan Tunggal (Schikuta, 2008)*

Di jaringan saraf tiruan dengan lapisan tunggal, neuron yang di organisasikan dalam beberapa layer-layer yang paling sederhana. Pada jaringan ini mempunyai input layer dari node sumber, dimana informasi diproyeksikan ke output layer dari neuron tapi tidak bisa sebaliknya. Jaringan ini adalah tipe *feedforward input layer* dari node sumber tidak dihitung karena tidak ada perhitungan yang dilakukan.

b. Jaringan dengan banyak lapisan (*Multilayer net)*

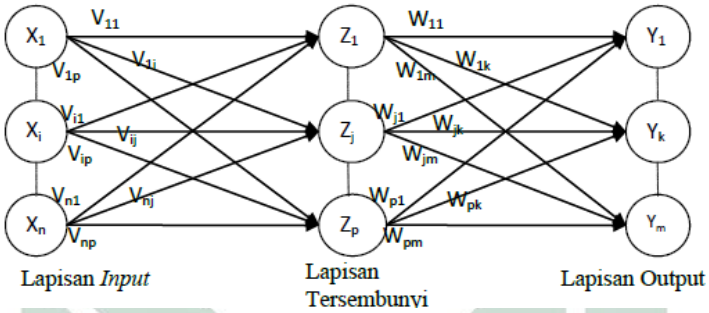


**Gambar 2. 2** *Jaringan Multilayer (Schikuta, 2008)*

Pada jaringan banyak lapis, memiliki kemampuan yang lebih, dalam memecahkan suatu masalah pelatihannya lebih rumit bila dibandingkan dengan jaringan lapis tunggal. Pelatihan pada jaringan ini lebih baik dikarenakan dapat bagi jaringan dalam memecahkan masalah yang tidak dapat diselesaikan jaringan berlapis tunggal karena jaringan tidak bisa dilatih untuk menampilkan secara benar.

c. Jaringan dengan lapisan kompetitif (*Competitive layer net)*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

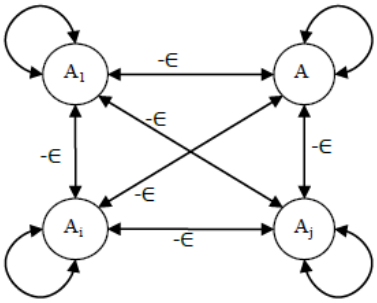


**Gambar 2. 3** *Jaringan lapisan kompetitif (Schikuta, 2008)*

Jaringan dengan lapisan kompetitif merupakan jaringan saraf tiruan yang sangat besar. Hubungan dengan antar neuron pada lapisannya tidak dapat ditunjukkan pada arsitekturnya tidak seperti jaringan yang lain. Pada jaringan ini kumpulan neuron bersaing untuk mendapatkan haknya agar menjadi aktif atau disebut dengan prinsip *winner takes all* atau yang disebut menanglah yang mengambil semua bagiannya.

2.2.8. Normalisasi Data

Normalisasi data adalah mengubah data sesuai kebutuhan menjadi lebih kecil. Tranformasi 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]. Berikut persamaan untuk normalisasi data pada persamaan 2.1 dan 2.2 (Agustina, Anggraeni and Mukhlason, 2005)

Tranformasi digunakan untuk mengubah data menjadi interval [0,1] adalah :

$$X = 0{,}8 * (X_P - min\,\{X_P\}) \,/\, (\max\{X_P\} - \min\{X_P\}) + 0{,}1 \qquad (2.1)$$

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

$$X = 2 * (X_P - min\,\{X_P\}) \,/\, (\max\{X_P\} - \min\{X_P\}) - 1 \qquad (2.2)$$

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.

*2.2.9. Denormalisasi*

Denormalisasi data adalah mengembalikan data kebentuk semula, tahap ini sangat penting untuk dilakukan agar data dari hasil peramalan dengan algoritma



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

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 2.6 :

$$X = \frac{(X_P - 0{,}1) * (max\{X_P\}) - \min\{X_P\})}{0{,}8} + \min\{X_P\} \qquad (2.3)$$

Menurut (Agustina, Anggraeni and Mukhlason, 2005) perubahan yang digunakan dalam denormalisasi data dalam interval [-1,1] adalah pada persamaan 2.7 :

$$X = 0{,}5 * (X_P + 1) * (max\{X_P\}) - \min\{X_P\}) + \min\{X_P\} \qquad (2.4)$$

Keterangan :

*x* = nilai data setelah di denormalisasi

$X_P$ = Data *output* sebelum di denormalisasi,

*min* ($X_P$) = Data minimum pada data set sebelum di normalisasi,

*max* ($X_P$) = Data maksimun pada data set sebelum di normalisasi.

2.2.10. Metode Extreme Learning Machine

*Extreme learning machine* merupakan metode syaraf tiruan untuk pembelajaran terbaru. Metode ELM diperkenalkan oleh Huang (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).* Metode pembelajaran ELM digunakan dalam mengatasi beberapa kelemahan dari jaringan saraf tiruan khususnya pada bagian kecepatan pembelajaran atau *learning speed.* Huang *et al* mengatakan ada dua alasan kenapa dalam proses JST *feedforward* lain mempunyai kecepatan pembelajaran atau *leraning 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.

Sedangkan pada pembelajaran *extreme learning machine* parameter – parameter untuk *input bobot* dan *hidden bias* digunakan secara acak maka dari itu pembelajaran ELM memiliki *learning speed* yang cepat dan mampu menghasilkan *good generalization performance.* Model ELM dalam matematika berbeda dari jaringan syaraf tiruan lainnya dan model ELM dalam matematika ini mempunyai



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

persamaan yang efektif dan sederhana daripada model matematika jaringan saraf tiruan. Berikut ini model matematika dari ELM. Pada simbol N adalah jumlah yang dimisalkan yang berbeda disimbolkan dengan (*Xi* , *ti*).

$$Xi = [\, Xi_1 , Xi_2 , ...., Xi_n \,]^T \in R^n \qquad (2.5)$$

$$Xt = [\, Xt_1 , Xt_2 , ...., Xt_n \,]^T \in R^m \qquad (2.6)$$

Untuk *SLFNs* jumlah *hidden* neuron berjumlah *N* dan *activation function* nilai *g ( x )* dapat digambarkan sebagai berikut :

$$\sum_{i=1}^{N} \beta_i g_i \ (x_j) = \sum_{i=1}^{N} \beta_i g(w_i , x_{bi}) = O_i \qquad (2.7)$$

$$\beta = H * T \qquad (2.8)$$

Keterangan :

*w* = Merupakan vektor dari *weight*
*β*i = Merupakan *weight vector* yang menghubungkan ***i*** th *hidden* dan *output nodes.*
*bi= threshold* dari *i* th *hidden nodes.*
*w i x j* = Merupakan *inner* produk dari ***w i*** dan *x j*

Pada SLFNs dengan lapisan jumlah unit *hidden* dan fungsi $g(x)$ diasumsikan dapat meng-approksimaksi dengan tingkat kesalahan 0 atau dapat dinotasikan sebagai berikut:

$$\sum_{i=1}^{n} ||y_i - t_i|| = 0 \ sehingga \ y_i = t_i \qquad (2.9)$$

$$\sum_{i=1}^{N} \beta \ ig \ (W_i \,.\, X_j + b_i = \ t_i \qquad (2.10)$$

Dimana :
$y_i$ = Nilai hasil dari jaringan saraf tiruan

$t_i$ = Nilai target yang diperoleh pada setiap keluaran

Jika jumlah *input* data sebanyak $n$ dengan jumlah *hidden layer* yang diinisiasikan sebanyak $m$, maka dapat dibentuk menjadi sebuah matriks $H$ yang berisikan output dari hasil perhitungan pada *hidden layer* yang berukuran $m \times n$



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

jumlah lapisan *hidden* dikali dengan jumlah *input* sehingga matriks yang terbentuk dapat dilihat pada persamaan:

$$H = \begin{bmatrix} g(x_1 * w_1, 1 + b_1) & \cdots & g(x_1 * w_1, m + b_m) \\ \vdots & \ddots & \vdots \\ g(x_1 * w_n, 1 + b_1) & \cdots & g(x_n * w_n, m + b_m) \end{bmatrix} \quad (2.11)$$

$$\beta = \begin{matrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{matrix} \quad (2.12)$$

$$T = \begin{matrix} t_1^T \\ \vdots \\ t_N^T \end{matrix} \quad (2.13)$$

Sehingga persamaan dapat ditulis sebagai berikut :

$$T = \beta H \quad (2.14)$$

H adalah pada persamaaan 2.10 *hidden layer output matrix.* $g(w_1 * x_1 + b_1)$ menunjukan hasil keluaran dari *hidden nodes* berhubungan dengan nilai *input* $x_1$. $\beta$ merupakan matrix dari output *weight* dan *T* matrix dari target atau *output.*

Pada ELM masukan bobot dan bias *random*, maka hasil keluaran nilai bobot yang diperoleh dari hubungan hidden layer ditentukan menggunakan persamaan berikut :

$$\beta = H^T T \quad (2.15)$$

Dengan $H^T$ merupakan hasil yang berasal dari matriks pseudoinverse dari matriks H.

*2.2.11.* Arsitektur ELM

Dibawah ini merupakan gambar dari struktur ELM, struktur pada ELM terdiri atas *input layer* yang berisi variabel bebas, *hidden layer*, dan *output layer (sales forecast).*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

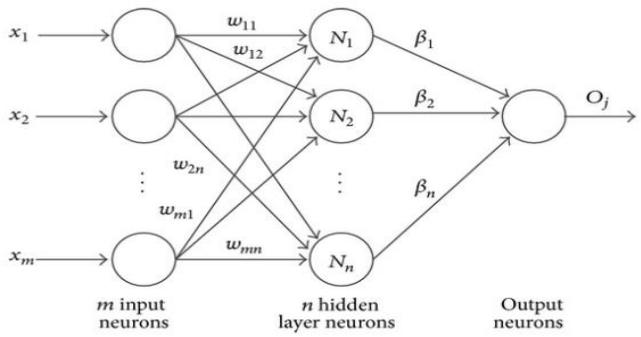


***Gambar 2. 4*** *Struktur ELM (Prakoso, Wisesty and ., 2016)*

Pada proses *testing ELM* hasil dari *input weight* dan *output weight* yang diperoleh dari proses hasil *training*, tahap selanjutnya melakukan peramalan dengan *ELM*. Data yang digunakan meliputi 20% untuk data *testing* dari jumlah data. Pada tahap *input* nilai yang akan di normalisasikan terlebih dahulu diubah dengan *range* dan rumus normalisasi yang sama pada data *training*. Maka hasil dari proses ELM harus melalui proses denormalisasi agar mudah dalam membaca nilai. Dibawah ini akan di jelaskan algoritma dalam kerja ELM (G. Huang, Zhu and Siew, 2004).

### 2.2.12. Algoritma ELM

Pada algoritma ELM ada beberapa proses yaitu terdiri atas tiga proses, yaitu inisialisasi bobot *input* dan bias, penghitungan *output* dari *hidden layer*, dan penghitungan bobot akhir. Pada tahap menginisialisasi bobot *input* dan bias, untuk nilai bobot setiap unit *input* adalah (*Xi*) yakni *a* dan bias yakni *b* diperoleh dari hasil random. Setiap unit untuk *hidden* akan dihitung jumlah keluaran yang dihasilkan dengan persamaan berikut $g(w_1 * x_1 + b_1)$ Kemudian, bobot akhir ($\beta$) dihitung dan setelah itu di aktivasi dengan menggunakan sebuah fungsi aktivasi *sigmoid*. Pada proses *training*, setiap unit *output* membandingkan aktivasinya dengan nilai target tujuannya untuk menentukan tingkat kesalahan *error*. Jika *error* masih melebihi dari yang diharapkan, proses penginisialisasi bobot *input* dan bias akan diulangi sampai menemukan bobot yang optimal (G. Bin Huang, Zhu and Siew, 2004).

#### 2.2.12.1. Prosedur Pelatihan

Berikut adalah langkah – langkah dalam pelatihan metode ELM :



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

a) Menginisialisasi bobot dan bias.
b) Jika terdapar *error* belum terpenuhi, maka melakukan langkah c sampai langkah e.
c) Setiap unit *input* ($x_1,,,,,x_n$ ) menerima sinyal input dan menyebarkan sinyal tersebut pada seluruh unit lapisan di atasnya (unit *hidden*).
d) Setiap hasil keluaran dari *hidden layer* dihitung dengan persamaan di samping $g(w_1, x_1, b_1)$.
e) Nilai bobot akhir dari *hidden layer*($\beta$) dihitung menggunakan persamaan

$$\beta = H^{+}T \qquad (2.16)$$

f) Memeriksa *stop condition*. Dengan cara membatasi nilai kesalahan *error* yang dihitung dengan *Mean Square Error* (*MSE*). MSE merupakan metode untuk menghitung *error* dari dengan mengkuadratkan nilai peramalan dan nilai sebenarnya (Agustina, Anggraeni and Mukhlason, 2005).

2.2.13. Jumlah Ketetapan *Hidden Layer*.

Jumlah *neuron* berpengaruh pada keakuratan dengan hasil peramalan terhadap data yang digunakan dalam pembelajaran ELM. Percobaan jumlah *neuron* pada *hidden layer* cocok digunakan untuk peramalan dengan melakukan beberapa kali proses *training*. Target *erorr* adalah 0,001, proses segera berhenti bila nilai fungsi kinerja kurang sama dengan target *error* yang ditentukan. Jumlah *Neuron hidden* yang pertama di awali dengan jumlah *neuron hidden* ke 3 karena nilai paling bawah untuk proses *training* (Radjabaycolle and Pulungan, 2016).

2.2.14. Prosedur Pengujian

Setelah melakukan pelatihan JST ELM maka langkah selanjutnya melakukan pengujian dengan langkah sebagai berikut :

a) Menginisialisasi bobot (dari algoritma pelatihan) atur fungsi aktivasi yang digunakan
b) Setiap unit *input* ($x_1,,,,,x_n$ ), hitung keluaran jaringan (Y).
c) Mengubah keluaran jaringan dengan menggunakan fungsi aktivasi (Agustina, Anggraeni and Mukhlason, 2005).



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*2.2.15.* Ukuran Kesalahan dengan *MSE (Mean Squared Error)*

Ukuran Kesalahan dalam penelitian ini menggunakan *MSE (Mean Squared Error)* yang termasuk ukuran standart statistika merupakan nilai rata-rata kesalahan kuadrat *MSE.* Hasil dari tingkat akurasi tersebut yakni berupa angka desimal yang mendekati nilai 1, untuk ukuran kesalahan kuadrat *MSE* berikut adalah rumusnya (Khotimah, Sari R and Yulianarta, 2010)*:*

$$MSE = \frac{\sum e_i^2}{n} = \frac{\sum (X_i - F_i)\,2}{n} \qquad (2.17)$$

Keterangan :

E = Error Peramalan

$n$ = Jumlah Data

$x_i$ = Data nyata ke i

$F_i$ = Data peramalan ke i

Untuk hasil peramalan tidak selalu sesuai dengan data aktualnya. Perbedaan hasil ramalan dan data yang sesunggunya disebut kesalahan dalam ramalan. Ketetapan dalam metode peramalan diperoleh dengan cara mencari nilai selisih ukuran kesalahan peramalan. Sehingga pada umunya semakin kecil ukuran *MSE.* Maka ramalan akurat (Rahmadayanti, Susilo and Puspitaningrum, 2015).

2.2.16. Ketetapan Metode dalam Peramalan

Metode peramalan digunakan dalam penelitian tergantung dengan kriteria dan pola data yang digunakan. metode untuk peramalan tidak ada yang dapat dilakukan dengan tepat oleh sebab itu setiap metode menghasilkan kesalahan *error.* Semakin kecil kesalahan *error* yang dihasilkan maka peramalan yang digunakan semakin baik. berikut kriteria untuk akurasi dalam menilai kesalahan *error* menggunakan rumus ketetapan *MAPE* pada tabel 2.2 (Ilmiyah, 2018).

$$MAPE = \frac{1}{n}\sum_{t=1}^{n} \frac{Nilai\ error}{Data\ Actual} X\ 100\% \qquad (2.18)$$

Keterangan :

$n$ = Banyaknya data

*Nilai Error* = data aktual dikurangi data peramalan



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*Tabel 2. 2 Kriteria MAPE*

| | |
|---|---|
| Peramalan sangat baik | Nilai *MAPE* < 10% |
| Peramalan baik | Nilai *MAPE* 10% - 20% |
| Peramalan cukup | Nilai *MAPE* 20% - 50% |
| Peramalan Tidak Akurat | Nilai *MAPE* > 50% |

### *2.2.17. Python*

*Python* merupakan bahasa pemroggraman yang mudah dipahami dan mudah dipelajari oleh orang yang baru belajar pemroggraman karena struktur sintaknya tersusun rapi. Python pertama kali dibuat oleh Guido van Rossum di negara Belanda, pada tahun 1990 dan namanya diambil dari acara televisi kesukaan Guido Monty Python's Flying Circus. Van Rossum mengembangkan *Python* sebagai hobi, kemudian Python menjadi bahasa pemrograman yang dipakai secara luas dalam industri dan pendidikan karena sederhana, ringkas, sintaks intuitif dan memiliki pustaka yang luas (Jeno, Dengen and Budiman, 2019).

*Python* memiliki standar *library* yang secara umum mudah untuk dipelajari dan berisi modul-modul khusus untuk threading, jaringan, database, dll (Jaskolka *et al.*, 2019). Maka dari itu bahasa pemrograman yang digunakan untuk implementasi metode ELM dalam peramalan pemakain konsumsi listrik menggunakan bahasa pemrograman *python.*

## 2.3. Integrasi Keislaman

Konsumsi listrik sangat penting dalam kebutuhan sehari – hari, dalam situasi apapun listrik sangat dibutuhkan oleh manusia dalam kebutuhan hidup. Semakin berkembangnya teknologi yang pesat saat ini, semua yang digunakan membutuhkan kebutuhan listrik. Sehingga kebutuhan listrik dari waktu ke waktu terus menerus meningkat dan perusahaan penyedia listrik menyediakan pasokan listrik secara belebihan agar bisa memenuhi kebutuhan hidup, disamping itu penyediaan listrik secara berlebihan akan memberikan dampak kerugian dan mengeluarkan biaya besar terbuang sia-sia. Islam mengajarkan umatnya untuk tidak beperilaku berlebihan atau "boros", karena Allah SWT. Tidak menyukai orang



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

yang “berlebihan” dan Al-Quran memiliki cara agar manusia tidak terjebak dalam sifat berlebihan. Berdasarkan hasil wawancara dengan ustad M. Shollihidin, M.HI selaku dosen dari fakultas Hukum Syariah, beliau menjelaskan bahwa Allah SWT. Sudah menjelaskan di dalam Al-Quran yaitu sifat boros dapat merugikan manusia. seperti dalam Al-Quran surah Al-Isra, ayat 27:

إِنَّ ٱلْمُبَذِّرِينَ كَانُوٓا۟ إِخْوَٰنَ ٱلشَّيَٰطِينِ ۖ وَكَانَ ٱلشَّيْطَٰنُ لِرَبِّهِۦ كَفُورًا

Terjemah Arti: Sesungguhnya pemboros-pemboros itu adalah saudara-saudara syaitan dan syaitan itu adalah sangat ingkar kepada Tuhannya.( QS. Al-isra, ayat 27)

Surat Al-Isra yang dikenal dengan surah Bani Israil yang termasuk surat Makiyah karena di turunkan di kota Mekkah. Khususnya ayat 26 - 27 memiliki asbabun nuzul diriwayatkan oleh At-Tabrani bersumber dari Abu Said Al-Khudri dalam riwayat lain berasal dari Ibnu Abbas bahwa ketika ayat ini turun Rasulullah SAW memberikan tanah Fadak atau tanah yang diperoleh Rasulullah dari rampasan perang atau pembagian kepada Fatimah.

Didalam ayat tersebut Allah SWT. mengingatkan betapa buruknya sifat orang boros dan dikatakan sebagai saudara setan. Maka Allah SWT menganjurkan kepada manusia untuk tidak bersikap boros dalam kehidupan atau membuang sesuatu yang berlebihan / mubadzir. Mubadzir adalah salah satu dari sifat setan. Setan adalah makhluk yang mungkar kepada Allah SWT. Jika manusia bersikap mubadzir sama halnya manusia tersebut mungkar kepada Allah SWT. Selain itu mubadzir dapat mendatangkan dampak negatif, sehingga mubadzir adalah sikap yang tercela. Maka dari itu dalam hal konsumsi listrik lebih baik menanamkan sifat menghemat seperti pada siang hari lampu dan barang elektronik yang tidak membutuhkan listrik dimatikan agar tidak mengalami tingginya pemakaian daya listrik yang berdampak pada pembangkit listrik yang terus mengalami peningkatan.

Sikap boros juga sudah di jelaskan dalam hadist yaitu HR. Muslim no. 1715) :



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

إِنَّ اللَّهَ يَرْضَى لَكُمْ ثَلاَثًا وَيَكْرَهُ لَكُمْ ثَلاَثًا فَيَرْضَى لَكُمْ أَنْ تَعْبُدُوهُ وَلاَ تُشْرِكُوا بِهِ شَيْئًا وَأَنْ تَعْتَصِمُوا بِحَبْلِ اللَّهِ جَمِيعًا وَلاَ تَفَرَّقُوا وَيَكْرَهُ لَكُمْ قِيلَ وَقَالَ وَكَثْرَةَ السُّؤَالِ وَإِضَاعَةَ الْمَالِ

"Sesungguhnya Allah meridhai tiga hal dan membenci tiga hal bagi kalian. Dia meridhai kalian untuk menyembah-Nya, dan tidak menyekutukan sesuatu pun dengan-Nya, serta berpegang teguhlah kalian dengan tali Allah dan tidak berpecah belah. Dia pun membenci tiga hal bagi kalian, menceritakan sesuatu yang tidak jelas sumbernya, banyak bertanya, dan membuang-buang harta." (HR. Muslim no. 1715)

Didalam hadist tersebut terdapat Ada tiga hal yang Allah benci yaitu Qila Wa Qaal yang artinya menceritakan sesuatu yang tidak jelas sumbernya, kemudian banyak bertanya, dan menghamburkan harta. Untuk itu sebagai umat islam dilarang meniru perbuatan 3 hal yang sudah dijelaskan diatas. Dalam masalah menghamburkan harta sama halnya didalam mengkonsumsi listrik dianjurkan untuk menghemat listrik agar tidak terbuang sia-sia seperti jika disiang hari lampu dirumah sebaiknya di matikan karena dengan adanya cahaya matahari sudah cukup menerangi, dengan membiasakan hidup hemat kita bisa mengurangi jumlah penggunaan energi listrik dan sebagai umat islam terhindar dari sifat mubadzir.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# BAB III
# METODOLOGI PENELITIAN

## 3.1. Alur Penelitian

Pada alur bab ini peneliti menjelaskan langkah – langkah dalam melakukan penelitian. Berikut ini tahapan – tahapan dalam penelitian yang akan dilakukan.

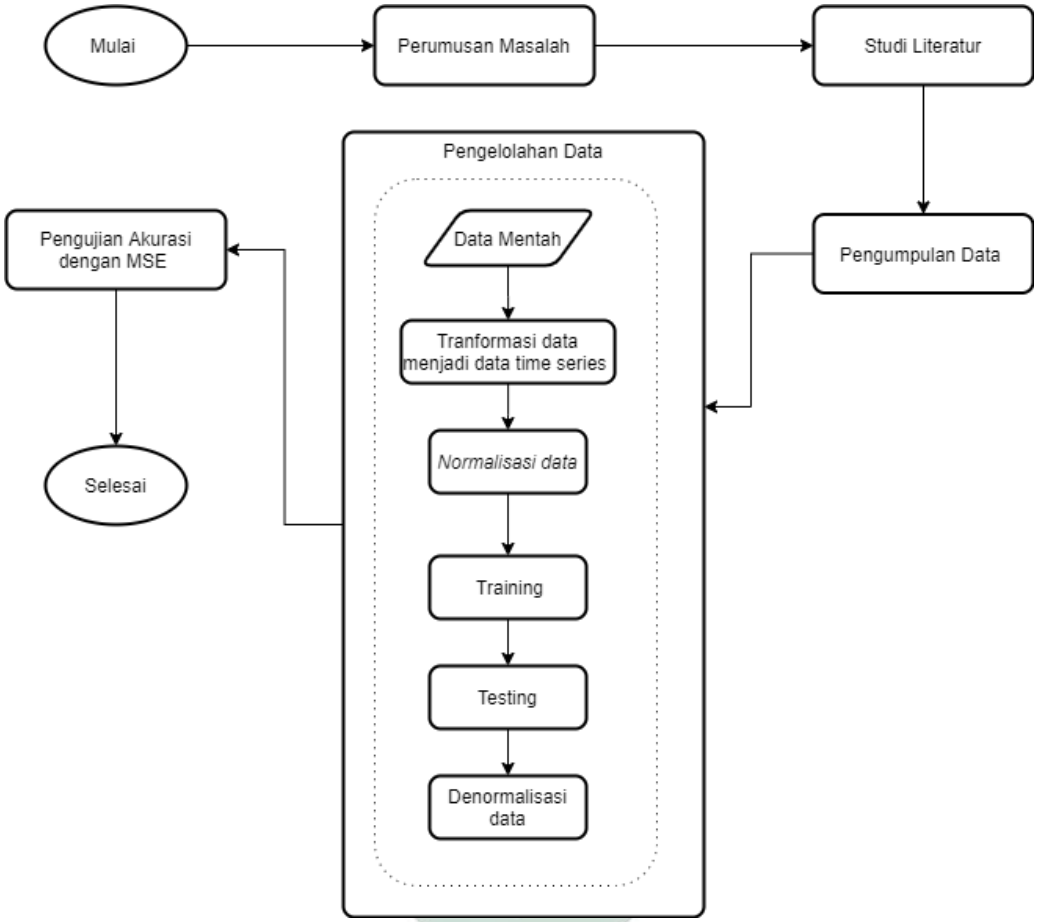


*Gambar 3. 1 Flowchart Model Penelitian*

### 3.1.1. Perumusan Masalah

Pada tahap ini merupakan tahap pertama dalam penelitian yaitu perumusan masalah, perumusan masalah ini diambil dari masalah yang dipaparkan di latar belakang dalam pembuatan penelitian mengenai peramalan konsumsi listrik disebuah daerah. Pada penelitian ini metode yang digunakan adalah *Extreme Learning Machine* dengan mendapatkan hasil peramalan yang mendekati akurasi dan membantu perusahaan ketenagalistrikan mendapatkan informasi yang dapat berguna untuk di pertimbangkan dalam penyediaan permintaan listrik di masa mendatang.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

### 3.1.2. Studi Literatur

Pada tahapan studi literatur ini dilakukannya pembelajaran dengan penelitian terdahulu yang terkait dengan peramalan konsumsi dan implementasi metode *Extreme Learning Machine* pada dataset pemakaian listrik di kwh meter dan pembelajaran dengan bahasa pemrograman. Sumber didapatkan untuk bahan sebagai studi literatur bersumber dari buku, jurnal, skripsi peramalan lainnya, dan internet sebagai bahan untuk memperkuat permasalahan dalam peramalan pemakaian konsumsi listrik.

### 3.1.3. Pengumpulan Data

Pada bagian ini, data yang diperoleh merupakan data sekunder. Data sekunder merupakan data yang di peroleh dari sumber atau pihak lain yang sudah ada yaitu dari pihak PT. PLN (Persero) Balikpapan. Data yang digunakan adalah jenis data yang dibutuhkan dalam peramalan konsumsi kwh yaitu data pemakaian Kwh pelanggan pascabayar tarif R1 (Rumah Tangga Kecil dan R1M (Rumah Tangga Menengah) berupa hasil rekapitulasi data pemakaian listrik perpelanggan.

Teknik *sampling* merupakan teknik pengumpulan data yang dilakukan, dimana pengumpulan data dilakukan dengan dokumentasi berdasarkan data historis pemakaian konsumsi listrik pelanggan per bulan yang dilihat dari beberapa tahun yang dijadikan objek penelitian yaitu periode tahun 2011 – 2019. Data yang sudah di kumpulkan berkaitan dengan topik penelitian diperiksa terlebih dahulu. Tujuan di periksa untuk menguji kebenaran data yang telah diperoleh tersebut apakah mengalami kesalahan atau kekurangan. Jika sudah proses tersebut data dipilah dan dipilih sehingga mendapatkan data yang jelas, lengkap dan mudah dimengerti dan konsisten.

Populasi dalam penelitian ini adalah perusahaan kelistrikan di daerah Balikpapan. Penentuan sampel menggunakan teknik *random sampling* dimana dalam pemilihan sampel pelanggan secara acak dengan menggunakan beberapa pertimbangan dan kriteria-kriteria sesuai yang diharapkan. Sampel yang diambil adalah jumlah pelanggan yang berjumlah 1000 dengan harapkan dapat mewakili tarif yang sudah di tentukan.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

3.1.4. Pengelolahan Data

Jika data sudah terkumpul, maka langkah selanjutnya merupakan mengolah data. Untuk mengolah data menggunakan metode ELM yang terbagi menjadi 3 tahap yaitu normalisasi data¸ *training*, kemudian *testing*, dan terakhir adalah analisis hasil peramalan. Dibawah ini langkah – langkah secara umum metode *ELM* yang ditunjukkan pada gambar 3.2

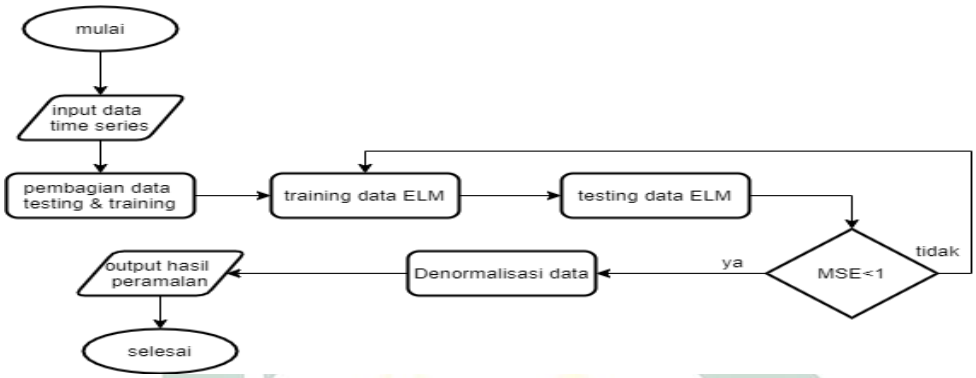


*Gambar 3. 2 Flowchart Metode ELM*

Berikut penjelasan masing-masing langkah – langkah menggunakan metode ELM.

*a.* Normalisasi Data

Data yang sudah di *time series* akan dinormalisasikan menjadi data yang lebih kecil yaitu ke interval [0,1] yang lebih kecil agar dapat digunakan untuk input ke jaringan dengan mengubah data menjadi angka desimal menggunakan persamaan 2.4. kemudian data yang sudah diubah kemudian di *inputkan* dengan jumlah *neuron* yang di *input* kan berjumlah 5 dimisalkan *n* jumlah data yang digunakan. Berikut rancangan data yang dapat dijelaskan pada tabel 3.1.

*Tabel 3. 1 Rancangan data untuk* normalisasi

| Pola ke- | Data *input* ($X_1, X_2, \ldots, X_5$) | | | | | Target |
|---|---|---|---|---|---|---|
| | $X_1$ | $X_2$ | $X_3$ | $X_4$ | $X_5$ | |
| 1. | *Data bulan januari2018 sebelumnya* | *data bulan janauri2019 sebelumnya* | *data bulan oktober sebelumnya* | *data bulan november sebelumnya* | *data bulan desember sebelumnya* | *data bulan 1* |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| | | | | | | |
|---|---|---|---|---|---|---|
| 2. | *Data bulan ke n-24* | *Data bulan ke n-12* | *Data bulan ke n-3* | *Data bulan ke n-2* | *Data bulan ke n-1* | *Data bulan n* |

Data *input* untuk peramalan terdiri atas 5 *input neuron* dengan asumsi dapat memberikan pola yang tidak rumit sehingga dapat melakukan pembelajaran yang baik.

*b. Training Data*

Sebelum ke proses peramalan langkah pertama dalam metode ELM adalah proses *traininig* yang bertujuan untuk memperoleh nilai hasil *output* bobot. Hasil dari proses *training* data nanti akan berlanjut ke dalam proses *testing* data. Sebelumnya data dibagi menjadi dua yaitu data *training* dan *testing.* Variabel yang digunakan dalam proses *training* adalah data dari bulan januari tahun 2011 sampai pada bulan desember 2018. Dibawah ini merupakan langkah – langkah untuk proses *training* data digambarkan dengan flowchart dibawah:

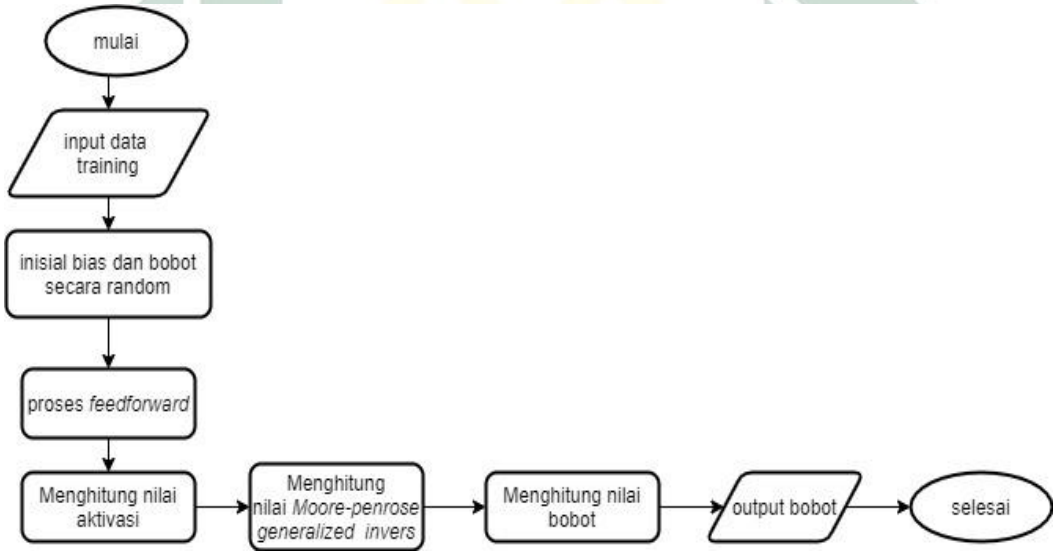


*Gambar 3. 3 Flowchart Training data*

1. Inisialisasi nilai *input* bobot dan bias dalam proses data *training*. Pada proses ini nilai yang diinisialisasi secara *random* -1 sampai 1.
2. Pada langkah kedua yaitu masuk kedalam proses feedforward, menghitung hasil *hidden* dengan menggunakan fungsi aktivasi *sigmoid* dengan persamaan berikut

   $$\left( H_{init\ i\ j} \right) = (\sum_{k}^{n} = 1\ W_{jk}\ .X_{ik}) +\ b_j \qquad (3.1)$$

   Dimana :



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

$H_{init\ i\ j}$ = matriks untuk hasil *hidden layer*

$i$ = jumlah seluruh data

$j$ = jumlah seluruh *neuron hidden*

$n$ = jumlah *neuron*

$w$ = hasil bobot / *weight*

$x$ = data masukan yang digunakan

$b$ = hasil nilai bias

3. Selanjutnya yaitu tahp menghitung matrik dengan aktivasi sigmoid $H(x)$
4. Langkah selanjutnya masuk ke tahap untuk menghitung Tranpose matriks *hidden layer* dengan menggunakan fungsi aktivasi sigmoid $H^T$
5. Selanjutnya menghitung nilai fungsi aktivasi sigmoid dengan persamaan

   $$H = \frac{1}{1+\mathrm{EXP}((-X_{train} \cdot W^T)+b)} \quad (3.2)$$

   Dimana : H = matrik *hidden layer*

   $X_{train}$ = Data Training

   $W^T$ = *Input weight transpose*

   $b$ = bias
6. Menghitung matrik *Moore-Penrose Generalized Invers* dengan rumus

   $$H^+ = (H^T\mathrm{H})^{-1}\ H^T \quad (3.3)$$
7. Selanjutnya menghitung hasil *output weight* dengan rumus dibawah, langkah ini adalah langkah terakhir dari proses *training data.*

   $$\beta = H^+\mathrm{T} \quad (3.4)$$

*c. Testing Data*

Pada proses ini merupakan proses evaluasi metode *Extreme Learning Machine* setelah proses di sub bab diatas, data variabel yang digunakan untuk *testing* data merupakan data yang berasal dari bulan januari tahun 2017 sampai data desember tahun 2019. Tujuan dari proses *testing* mendapatkan hasil dari peramalan. Data yang digunakan dimulai dari data bulan berikut ini langkah-langkah yang digambarkan dengan *flowchart 3.4.*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

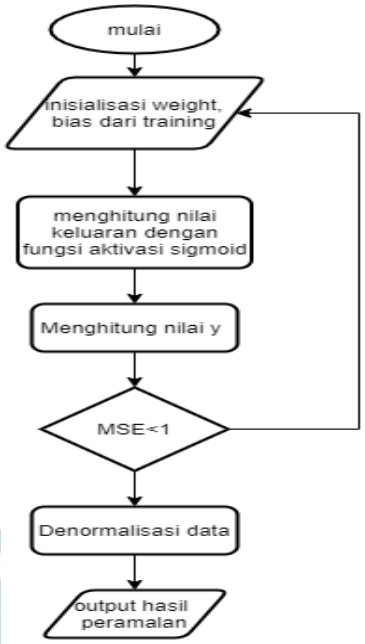


*Gambar 3. 4 Flowchart Testing data*

1. Menginisialisasi nilai *input bias, bobot* untuk nilai bobotnya berasal dari proses *training data.*
2. Menghitung nilai matriks *hidden layer* menggunakan fungsi aktivasi *sigmoid* berikut ini persamaannya:

   $$H = \frac{1}{1+EXP((-X_{test} \cdot W^T)+b))} \quad (3.5)$$

3. Langkah berikutnya menghitung hasil dari peramalan dengan rumus :

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

   Dimana :

   Y = hasil peramalan

   *H = output hidden layer*

   β = *output weight*

4. Langkah berikutnya menghitung nilai kesalahn *error* untuk melihat seberapa akurasi metode yang digunakan dengan nilai sebenarnya. Menghitung nilai kesalahan *error* menggunakan MSE (*Mean Sequared Error)* yang sudah ada di persamaan 2.17.
5. Melakukan denormalisasi dengan tujuan dapat mengembalikan nilai semula setelah di normalisasi pada tahap sebelum dilakukan proses *training data* berikut persamaan untuk denormalisasi data :



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

$$X = \frac{(X_P - 0{,}1) * (max\{X_P\}) - \min\{X_P\})}{0{,}8} + \min\{X_P\} \qquad (3.7)$$

Keterangan :

$x$ = nilai data yang sudah denormalisasi

$X_P$ = Data hasil peramalan

$min\ (X_P)$ = Data minimum untuk data set,

$max\ (X_P)$ = Data maksimun pada data set.

d. Pengujian Validasi Data

Pada pengujian validasi digunakan untuk menguji kevaliditas data dalam metode peramalan. Uji validasi pada penelitian ini menggunakan rumus *MSE (Mean Squared Erorr).* Kelebihan MSE sederhana dalam perhitungannya dengan menghitung hasil kuadrat *error* dalam peramalan di setiap periode yang ditentukan dan membagi total periode dalam peramalan yang ditentukan. Untuk menghitung MSE menggunakan persamaan 2.17.

3.1.5. Variabel Penelitian

Variabel yang digunakan dalam peramalan konsumsi listrik pelanggan adalah data pemakaian konsumsi listrik pelanggan pada periode Januari 2011 – Desember 2019 dengan sampel data diambil dari 2 tarif yaitu pelanggan rumah tangga (R1) dan pelanggan rumah tangga premium (R1M). Banyaknya data yang digunakan adalah jumlah pelanggan pertarif yaitu 1000 pelanggan setiap tarif. Kemudian untuk variabel prediktornya atau pola yang akan dibentuk diambil dari satu, dua, tiga, dua belas, dan dua puluh empat bulan sebelumnya sebagai data *inputan*. Berikut adalah rancangan data yang digunakan dimisalkan *n* untuk jumlah data yang digunakan bisa dilihat pada tabel 3.2

*Tabel 3. 2 Variabel Input*

| Pola ke- | Data *input* ($X_1, X_2, \ldots, X_{24}$) | | | | | Target |
|---|---|---|---|---|---|---|
| | ***X-24*** | ***X-12*** | ***X-3*** | ***X-2*** | ***X-1*** | |
| 1. | *Data bulan januari2017 sebelumnya* | *data bulan janauri2018 sebelumnya* | *data bulan oktober sebelumnya* | *data bulan november sebelumnya* | *data bulan desember sebelumnya* | *data bulan 1 januari 2019* |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| | | | | | | |
|---|---|---|---|---|---|---|
| 2. | *Data bulan februari2017 sebelumnya* | *Data bulan februari2018 sebelumnya* | *Data bulan november sebelumnya* | *Data bulan desember sebelumnya* | *Data bulan januari sebelumnya* | *Data bulan 2 februari 2019* |
| 3. | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 4. | *Data bulan ke n-24* | *Data bulan ke n-12* | *Data bulan ke n-3* | *Data bulan ke n-2* | *Data bulan ke n-1* | *Data bulan n* |

Dengan data masukan berjumlah 5 *neuron*, diharapakan dapat membangun pola yang tidak rumit sehingga dapat dilakukan untuk pembelajaran yang baik.

### 3.1.6. Lokasi dan Objek Penelitian

Penelitian yang berjudul Peramalan Konsumsi listrik di daerah Balikpapan menggunakan metode *Extreme Learning Machine* berlokasi di Kota Balikpapan khususnya di PT. PLN ULP Balikpapan. Penelitian ini dilakukan pada bulan April – Juni 2020.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# BAB IV
# PEMBAHASAN

Pada bab ini akan dijelaskan pengolahan data, penerapan jaringan syaraf tiruan *Extreme Learning Machine* untuk peramalan konsumsi listrik dan hasil implementasi menggunakan bahasa pemrograman *Python* untuk peramalan konsumsi listrik pelanggan perbulan.

## 4.1. Hasil Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang berasal dari PT. PLN (Persero) ULP Balikpapan, dengan mengambil data pemakaian konsumsi listrik dari tahun 2011 - 2019. Data diambil pada periode Januari 2011 – Desember 2019. Berikut terdapat kutipan data tentang data konsumsi listrik pelanggan R1 (Listrik tarif rumah tangga kecil) di tabel 4.1, kemudian di tabel 4.2

*Tabel 4. 1 Kutipan Rancangan Pemakaian Konsumsi Pelanggan R1*

| No | ID_PELANGGAN | 2011 | | | | 2012 | | | | ... | | 2019 | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| | | Jan | feb | .. | Des | jan | feb | .. | des | | | jan | .. | des |
| 1 | 232010001911 | 970 | 946 | | 933 | 1017 | 976 | | 961 | | | 1030 | | 1204 |
| 2 | 232010002504 | 392 | 371 | | 305 | 436 | 411 | | 340 | | | 430 | | 522 |
| 3 | 232010002964 | 370 | 348 | | 346 | 414 | 366 | | 364 | | | 522 | | 664 |
| 4 | 232010003791 | 479 | 462 | | 448 | 522 | 473 | | 479 | | | 389 | | 439 |
| 5 | 232010011800 | 383 | 357 | | 348 | 426 | 384 | | 363 | | | 493 | | 507 |
| 6 | 232010021353 | 233 | 206 | | 157 | 277 | 252 | | 196 | | | 117 | | 134 |
| 7 | 232010060446 | 276 | 248 | | 256 | 291 | 289 | | 278 | | | 250 | | 308 |
| 8 | 232010071024 | 180 | 160 | | 169 | 195 | 197 | | 187 | | | 121 | | 97 |
| | | | | | | | | | | | | | | |
| 1000 | 232015042000 | 270 | 243 | | 250 | 282 | 289 | | 263 | | | 260 | | 200 |

terdapat kutipan rancangan data R1M ( Listrik tarif rumah tangga medium).

Data pemakaian di tabel 4.1 adalah data pelanggan listrik R1 (Pelanggan rumah tangga kecil) yang terdiri dari id_pelanggan, tahun, dan bulan beserta hasil dari konsumsi pemakaian listrik. Kemudian data di bagi menjadi dua bagian yaitu data *training 80%* dari januari tahun 2011 sampai desember tahun 2018, kemudian data *testing 20%* yaitu dari bulan januari 2017 sampai desember tahun 2019. Untuk pelanggan R1M (Rumah tangga medium) pada tabel 4.2.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*Tabel 4. 2 Kutipan Rancangan Pemakaian Konsumsi Pelanggan R1M*

| No | ID_PELANGGAN | 2011 | | | | 2012 | | | | ... | | 2019 | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| | | jan | feb | .. | Des | Jan | feb | .. | des | | | jan | .. | des |
| 1 | 232000124752 | 553 | 523 | | 468 | 582 | 559 | | 518 | | | 379 | | 409 |
| 2 | 232000292132 | 257 | 237 | | 255 | 299 | 278 | | 300 | | | 334 | | 355 |
| 3 | 232010011473 | 198 | 183 | | 193 | 218 | 217 | | 219 | | | 204 | | 142 |
| 4 | 232010011481 | 131 | 110 | | 133 | 142 | 141 | | 182 | | | 142 | | 136 |
| 5 | 232010013263 | 188 | 175 | | 172 | 236 | 223 | | 186 | | | 349 | | 330 |
| 6 | 232010014506 | 290 | 272 | | 261 | 303 | 283 | | 289 | | | 227 | | 270 |
| 7 | 232010016714 | 526 | 505 | | 452 | 536 | 555 | | 488 | | | 234 | | 266 |
| 8 | 232000124752 | 262 | 247 | | 210 | 309 | 294 | | 223 | | | 156 | | 183 |
| | | | | | | | | | | | | | | |
| 1000 | 232015042524 | 113 | 85 | | 92 | 138 | 106 | | 105 | | | 81 | | 87 |

Data pemakaian di tabel 4.2 merupakan data pelanggan listrik R1M (Pelanggan Rumah Tangga Medium) yang terdiri dari id_pelanggan, tahun, dan bulan beserta hasil dari konsumsi. Sama halnya dengan data R1(Rumah tangga kecil) untuk data R1M (Rumah tangga medium) di bagi menjadi dua bagian yaitu data *training* dari tahun 2011 sampai tahun 2018, kemudian data *testing* yaitu tahun 2017 sampai tahun 2019.

Hasil Data dibuatkan *plot time series* yang berguna untuk melihat pola bentuk data yang ditunjukkan pada gambar grafik 4.1. kemudian data *outlier* Pada gambar grafik 4.2 dan 4.3 digunakan untuk melihat bentuk pola pada data *training.*

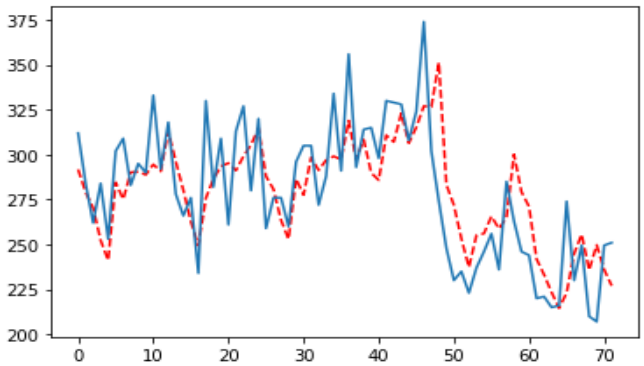


*Gambar 4. 1 plot time series data pelanggan pemakaian listrik*

Pada gambar 4.1 merupakan hasil gambaran *training* data yang membentuk pola data musiman dengan melihat tingkat naik turun pola yang akan digunakan.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

Pola musiman adalah pola data yang berulang kali di selang waktu tetap. Pada tabel 4.2 hasil *boxplot* dari data yang akan digunakan.

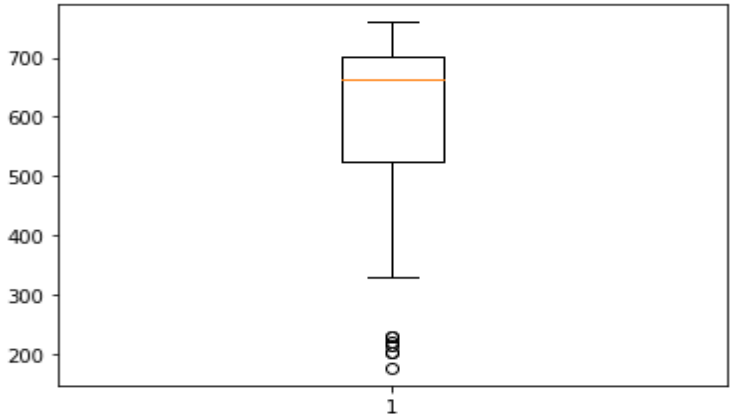


*Gambar 4. 2 Hasil Boxplot Outlier panjang 200 – 700*

Pada data 4.2 terdapat data yang *range* data pemakaian nya dari 200 - 700, dimana terdapat data yang terindikasi ekstrem tinggi maupun rendah, data pada gambar 4.2 terdapat lingkaran kecil dibawah kotak maka data tersebut merupakan data ekstrem rendah. Sama halnya pada gambar 4.3 data dengan range 600 – 1200.

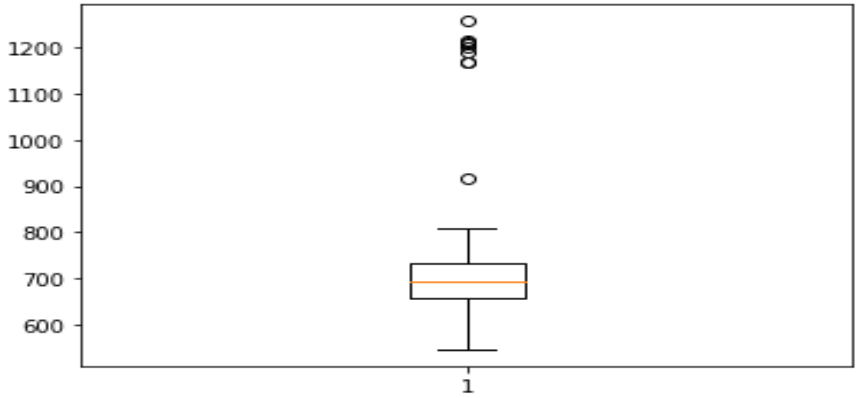


*Gambar 4. 3 Hasil Boxplot Outlier panjan 600 – 1200*

Pada gambar 4.3 merupakan data yang lingkaran kecilnya di atas kotak maka data tersebut dikatakan data yang terindikasi ekstrem tinggi sekitar *range* 1200. Untuk data dengan *range 100 -700* pada gambar 4.4



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

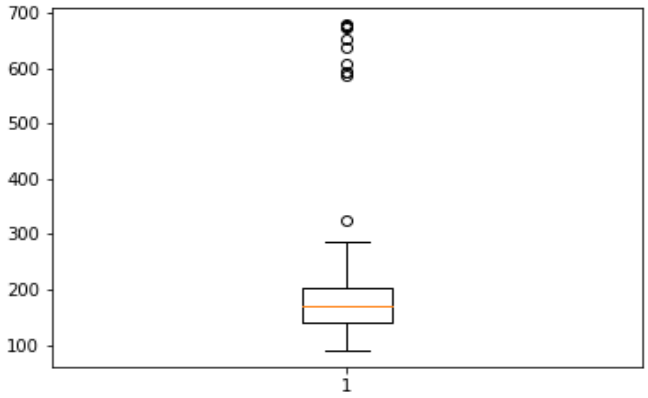


*Gambar 4. 4 Hasil Boxplot panjang 100 – 700*

pada gambar 4.4 menghasilkan data boxplot dari *range* 100 – 700 mendapatkan data yang terindikasi data ekstrem tinggi yang ditunjukan pada gambar 4.4 terdapat lingkaran di atas kotak. Data *outlier* dapat berpengaruh terhadap hasil dari peramalan. Jika semakin jauh data dari bangun persegi maka akan semakin ekstrem data yang dipakai. Maka dari itu perlu adanya *outlier* data untuk mengetahui data yang terindikasi ekstrem rendah dan data ekstrem tinggi agar data bisa di proses ke langkah selanjutnya. Langkah selanjutnya masuk kedalam proses pengolahan data yang dijelaskan di sub bab dibawah ini.

## 4.2. Pengolahan Data

Pada penelitian ini, *tools* yang digunakan merupakan Google Colab, yakni produk berbasis *cloud* digunakan secara gratis yang dibuat untuk para programmer dalam implementasi algortima. Pada penelitian ini Google Colab dalam bahasa *Python* digunakan untuk implementasi algoritma *Extreme Learning Machine* untuk kasus peramalan, sedangkan *Ms.Excel* digunakan untuk mengumpulkan dan mengolah data yang akan dipakai untuk peramalan. Berikut langkah – langkah dalam pengolahan data:

## 4.3. Preproscessing

### 4.3.1. Tranformasi data ke bentuk *Time Series*

Data yang sudah ada di tabel 4.1 dan 4.2 merupakan data dengan satu *parameter* berdasarkan waktu per bulan, diubah menjadi data berdasarkan kolom masukan dengan tujuan agar bisa digunakan untuk *input* dalam proses peramalan yang di tunjukan pada tabel 4.3.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*Tabel 4. 3 Tabel Time Series* pelanggan R1

| id_pelanggan | t-24 | t-12 | t-3 | t-2 | t-1 | target |
|---|---|---|---|---|---|---|
| 232000124752 | 534 | 587 | 423 | 336 | 440 | 379 |
| 232000292132 | 229 | 321 | 296 | 321 | 362 | 334 |
| 232010011473 | 189 | 256 | 71 | 167 | 156 | 204 |
| 232010011481 | 102 | 208 | 125 | 105 | 114 | 142 |
| 232010013263 | 166 | 241 | 350 | 339 | 383 | 349 |
| 232010014506 | 280 | 385 | 233 | 220 | 233 | 227 |
| 232010016714 | 480 | 565 | 192 | 201 | 275 | 234 |
| 232010018634 | 249 | 324 | 185 | 166 | 190 | 156 |
| 232010019050 | 326 | 403 | 362 | 344 | 375 | 354 |
| 232010020534 | 223 | 371 | 245 | 239 | 263 | 228 |
| 232010020784 | 312 | 393 | 233 | 204 | 212 | 207 |
| 232010021064 | 315 | 401 | 309 | 313 | 347 | 323 |
| 232010021282 | 446 | 553 | 310 | 276 | 299 | 312 |
| 232010021505 | 423 | 516 | 287 | 343 | 458 | 455 |
| 232010021588 | 162 | 278 | 135 | 125 | 154 | 134 |
| 232010022509 | 228 | 272 | 194 | 174 | 198 | 190 |
| 232010023923 | 465 | 492 | 201 | 188 | 203 | 195 |

Pada tabel 4.3. merupakan data R1 yang sudah di kelompokkan berdasarkan parameter yang di*inputkan* kedalam jaringan. Untuk data target adalah data tahun 2019, t-1 merupakan data satu bulan sebelumnya, t-2 adalah data 2 bulan sebelumnya, t-3 data 3 bulan sebelumnya, sedangkan t-12 adalah data bulan 12 sebelumnya pada tahun 2018, dan t-24 adalah data 2 tahun sebelumnya pada tahun 2017. Kemudian data di kelompokkan per pelanggan sesuai dengan parameter *inputan* sehingga membentuk 72 pola, sesuai dengan jumlah pembagian data *training.* Berikut ditunjukkan pelanggan ber ID 232010002504 salah satu kasus untuk tranformasi kedalam bentuk *time series* pada ditunjukkan pada tabel 4.4.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*Tabel 4. 4 Hasil time series per pelanggan*

| Hasil Time Series Data id Pelanggan 232010002504 : | | | | | | |
|---|---|---|---|---|---|---|
| Pola Ke- | t-24 | t-12 | t-3 | t-2 | t-1 | Target |
| 1 | 0.22186 | 0.36012 | 0.44855 | 0.36655 | 0.30707 | 0.39228 |
| 2 | 0.26045 | 0.25884 | 0.52411 | 0.44855 | 0.36655 | 0.30707 |
| 3 | 0.28456 | 0.34405 | 0.61414 | 0.52411 | 0.44855 | 0.36655 |
| 4 | 0.27170 | 0.34405 | 3,53889 | 0.61414 | 0.52411 | 0.44855 |
| 5 | 0.26688 | 0.31832 | 0.63665 | 0.5096 | 0.61414 | 0.52411 |
| 6 | 0.22186 | 0.34244 | 0.61897 | 0.63665 | 0.50964 | 0.61414 |
| 7 | 0.11897 | 0.37942 | 0.57717 | 0.61897 | 0.63665 | 0.50964 |
| 8 | 0.06591 | 0.28778 | 0.43890 | 0.57717 | 0.61897 | 0.63665 |
| 9 | 0.04180 | 0.37459 | 0.24437 | 0.43890 | 0.57717 | 0.61897 |
| 10 | 0 | 0.38263 | 0.36012 | 0.24437 | 0.43890 | 0.57717 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 72 | 0.17363 | 1 | 0.34405 | 0.25884 | 0.36012 | 0.24437 |

Pada tabel 4.3 terdapat data untuk memasukkan model pola yang digunakan untuk *training*, dalam satu pelanggan berisikan 72 pola data sesuai dengan jumlah data untuk *training*, pada tabel 4.3 merupakan contoh dari salah satu data pelanggan R1(Rumah tangga kecil) yang ber ID 232010002504. Pola data yang di *input* merupakan data dari waktu 1 bulan, 2 bulan, 3 bulan, satu tahun, dan dua tahun sebelumnya.

Untuk data pelanggan R1M nilai *input* yang digunakan untuk *training* modelnya sama dengan tabel 4.3, data dari waktu 1,2,3 bulan, 1 tahun, dan 2 tahun sebelumnya. Setiap pelanggan berjumlah 72 data untuk *input* model. Jumlah *input neuron* yang digunakan yakni ada 5 unit dengan harapan *neuron* yang di *input* kan memiliki jaringan arsitektur yang tidak terlalu rumit dan dapat melakukan pembelajaran dengan baik.

### 4.3.2. Normalisasi Data

Dalam tahap *preprocessing* data pemakaian konsumsi pelanggan R1 (Rumah tangga kecil) dan R1M (Rumah tangga medium) dinormalisasikan menggunakan persamaan 2.1. Setelah melalui tahap pembagian data *latih* dan data uji. Selanjutnya



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

pada tahap ini nilainya ditransformasi ke interval [0,1], berikut adalah *function* yang digunakan dalam implementasi algoritma berada pada tabel 4.5

*Tabel 4. 5 Function Normalisasi*

```
def Normalisasi(x,a,b):

    y = np.divide(np.dot(0.8,np.subtract(x,b)),(a-b))+0.1

    return y
```

Fungsi yang digunakan untuk normalisasi menggunakan persamaan 2.1. langkah pertama memberikan identitas fungsi yang bernama *Normalisasi* dengan parameter *x, a, b* dimana untuk *a* adalah nilai *max* kemudian untuk *b* adalah nilai *min*, *np.divide* digunakan untuk membagi operasi matematika sedangkan *np.dot* untuk operasi perkalian dan *np.subtract (x.b)* untuk operasi matriks dalam matematika. Kemudian mengembalikan nilai *y* dimana *y* adalah nama identifikasi untuk persamaan 2.1. Hasil dari kutipan data *training* pelanggan R1 (Rumah tanngga kecil) yang selesai di normalisasikan pada tabel 4.6 kemudian untuk hasil normalisasi *training* pelanggan R1M (Rumah tangga medium) ada di tabel 4.7.

*Tabel 4. 6 Hasil Normalisasi data* training *Pelanggan R1*

| IDPELANGGAN | Januari 2011 | Februari 2011 | Maret 2011 | ... | Desember 2018 |
|---|---|---|---|---|---|
| 232010001911 | 0,02335 | 0,01651 | 0,00427 | | 0,04214 |
| 232010002504 | 0,18328 | 0,14952 | 0,00000 | | 0,36013 |
| 232010002964 | 0,02866 | 0,01699 | 0,00000 | | 0,12420 |
| 232010003791 | 0,12567 | 0,10756 | 0,06070 | | 0,12354 |
| 232010011800 | 0,15645 | 0,14438 | 0,12721 | | 0,18849 |
| 232010021353 | 0,05496 | 0,04715 | 0,02864 | | 0,02285 |
| 232010022848 | 0,11496 | 0,08776 | 0,26082 | | 0,27812 |
| ⋮ | ⋮ | ⋮ | ⋮ | | ⋮ |
| 232015042000 | 0,07540 | 0,05117 | 0,04309 | | 0,04758 |

Pada tabel 4.6. Merupakan hasil dari normalisasi data *training* setiap pelanggan R1 dari periode january 2011 sampai desember 2018. Sedangkan di tabel 4.7 hasil normalisasi data *training* pelanggan R1M.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*Tabel 4. 7 Hasil Normalisasi data pelanggan R1M*

| IDPELANGGAN | Januari 2011 | Februari 2011 | Maret 2011 | | Desember 2018 |
|---|---|---|---|---|---|
| 232000124752 | 0,38475 | 0,33156 | 0,18440 | | 0,18440 |
| 232000292132 | 0,04173 | 0,01192 | 0,01937 | | 0,19821 |
| 232010011473 | 0,22000 | 0,20333 | 0,18333 | | 0,17333 |
| 232010011481 | 0,03634 | 0,01003 | 0,00125 | | 0,01504 |
| 232010013263 | 0,03654 | 0,01894 | 0,00000 | | 0,30041 |
| 232010014506 | 0,10294 | 0,07647 | 0,02500 | | 0,01912 |
| 232010016714 | 0,47324 | 0,44366 | 0,34366 | | 0,11972 |
| ⋮ | ⋮ | ⋮ | ⋮ | | ⋮ |
| 232015042524 | 0,05749 | 0,02395 | 0,01796 | | 0,02515 |

Berikut hasil dari proses normalisasi data disajikan pada tabel 4.5 dan tabel 4.6 kedalam interval kurang dari 1. Maka tahap selanjutnya masuk dalam proses *training* data yang dijelaskan pada sub bab 4.4

## 4.4. Perhitungan ELM untuk peramalan konsumsi listrik

Dalam implemantasi algoritma *Extreme Learning Machine* terdapat beberapa *libraries* yang dibutuhkan agar algoritma yang dijalankan dapat di*running*. Berikut beberapa *libraries* yang dibutuhkan untuk implementasi algoritma, disajikan pada tabel 4.4.

*Tabel 4. 8 Library yang digunakan*

| No | Jenis *Libraries* | Fungsi |
|---|---|---|
| 1. | *Numpy* | Digunakan untuk menjalankan operasi matriks dan vector. |
| 2. | *Pandas* | Digunakan untuk membaca *file* dari berbagai format yang di *import* kan seperti .txt, .csv, .tsv, dll. |
| 3. | *Scipy.linalg* | Digunakan untuk menangani operasi matriks dan aljabar dan operasi matematika lainnya yang lebih kompleks. |
| 4. | *Matplotlib* | Digunakan untuk menampilkan data dalam bentuk grafik yang lebih baik dan berwarna. Agar memudahkan untuk membaca data. |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| No | Jenis *Libraries* | Fungsi |
|---|---|---|
| 5. | *Math* | Digunakan untuk menjalankan fungsi matematika |
| 6. | *Time* | Digunakan untuk operasi waktu yakni mengembalikan waktu saat proses pembelajaran pada saat itu dengan jumlah detik. |

*Libraries* yang digunakan berjumlah 6, dan mempunyai peran masing – masing dalam setiap kegunaanya dalam implementasi algoritma. Langkah selanjutnya adalah proses *training* data yang dijelaskan pada sub bab dibawah ini.

### 4.4.1. Prosedur Training Data

Pada tahap *training data,* data yang digunakan untuk *training* per pelanggan ada 96 data dari bulan january 2011 sampai data desember 2018. Tahap *training* membutuhkan beberapa parameter untuk membentuk jaringan seperti halnya jumlah *neuron* dalam *menginput* bobot, fungsi aktivasi, *hidden layer,* dan bias. data yang dijadikan pola *input ELM* adalah data *x-1* merupakan sebulan sebelumnya¸ *x-2* merupakan dua bulan sebelumnya¸ *x-3* merupakan tiga bulan sebelumnya¸ *x-12* dua satu tahun sebelumnya¸dan data *x-24* dua tahun sebelumnya yang sudah di jelaskan pada tabel 3.2. Untuk bias dan bobot ditentukan secara *random,* langkah pertama dilakukan inisialisasi berguna untuk membangkitkan nilai awal untuk bias dan bobot. Ada beberapa *inisialisasi variabel* dalam proses ELM yang digunakan untuk *training* sebagai berikut:

$X$ : $x\text{-}1, x\text{-}2, \ldots, x_n$ : Parameter data *training* sebanyak *n*

$y$ : $y\text{-}1, y\text{-}2, \ldots, y_n$ : Parameter target data *training*

$w_n$ : inisialisasi bobot

$b$ : inisialisasi bobot bias

fungsi *sigmoid :* fungsi aktivasi yang digunakan.

$H$ : matriks *hidden layer*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

Berikut alur proses untuk algoritma ELM yang dijelaskan dibawah ini dijelaskan di tabel 4.9.

*Tabel 4. 9 Tabel Alur Training*

| |
|---|
| ***Proses Training data ELM*** |
| *Start* |
| *Input parameter (*jumlah *neuron, hidden layer)* |
| *Normalisasi data ()* |
| *Inisialisasi weight and bias ()* |
| Proses *feedforward ()* |
| *Search matriks H* |
| *Search pseudo invers dari matriks H* |
| *Output weight ()* |

Pada tabel 4.9 di jelaskan proses untuk mengolah data dalam proses *training* data. Berikut adalah *Function* yang digunakan dalam tahap *training* data berada pada tabel 4.10.

*Tabel 4. 10 Function untuk training data*

```
# Function activation sigmoid
def hidden_nodes(X,W,B):
    G = np.dot(X,W) + B
    H = 1 / (1 + np.exp(-G))
    return H
# Function for Training Process
def traine(X,Y,W,B):
    act_trdata = hidden_nodes(X,W,B) #Activation hidden nodes
    Hdegger    = la.pinv2(act_trdata)#MoorePenrose Pseudoinve
rse
    OutWeight  = np.dot(Hdegger,Y)   #Calculate OutWeight
        return OutWeight,W,B
```



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

Fungsi yang digunakan untuk *training* terdiri atas *function activation sigmoid,* dan *function process training.* Untuk *function activation sigmoid* identitas bernama *hidden_nodes* dengan parameter $X$ untuk data *training*¸$W$ untuk *input* nilai *weight, B* untuk nilai *bias.* Fungsi aktivasi yang digunakan sesuai dengan persamaan *3.2. G* merupakan inisial untuk menghitung hasil perkalian data *training* dan hasil output *weight/*bobot kemudian menjumlahkan nilai *bias.* Untuk inisial *hidden nodes* dengan huruf H untuk menghitung nilai exponen dari G. Kemudian untuk *function* proses *training* dengan mengidentifikasi nama *traine* yang berisi 4 parameter *X,Y,W,B.* Langkah pertama memanggil *function* untuk aktivasi *hidden nodes* dengan inisial nama *act.trdata.* langkah selanjutnya melakukan proses *moore penrose pseudoinvers* dengan menginisialkan nama Hdegger berisikan *la.pinv2* untuk membentuk matriks dari nilai matriks aktivasi sesuai dengan persamaan 3.3. selanjutnya menghitung nilai keluaran *weight* dengan inisial nama *OutWeight* yang berisikan *libreries np.dot* perkalian dari hasil matriks *Hdegger* yang sudah di proses *moore penrose pseudoinvers* dikalikan dengan parameter Y.

Berikut perhitungan manual peramalan pemakain konsumsi listrik dengan menggunakan percobaan 5 *input neuron* pada *hidden layer,* untuk matriks *w* nya berukuran *5x5,* dan untuk matriks *b* nya *1x5* dan berikut hasil perhitungan matriks pelanggan R1 yang ber ID 232010002504, untuk matriks *W dan biasnya* diperoleh secara *random* dengan interval [-1.1]:

$$W=\begin{bmatrix} -0.51764463 & -1.7985252 & -0.05566026 & 0.22568467 & -0.84782205 \\ 0.73151156 & -1.45607465 & 0.48346026 & 1.60177624 & -0.64110871 \\ 0.04352767 & 0.41898488 & -1.32794793 & -0.77668162 & 0.79541192 \\ 0.45875015 & -0.36133418 & -2.05440998 & -0.36688185 & 0.34818273 \\ -1.78436224 & 1.42414644 & -0.53180135 & 1.85195273 & -0.49280161 \end{bmatrix}$$

$$\beta = [0.88126138 \quad 0.28719737 \quad -1.6497583 \quad -0.83871808 \quad -0.54366908]$$

Tahap selanjutnya adalah mendapatkan hasil matriks *H* dengan menggunakan persamaan 2.11. berikut adalah perhitungan manualnya.

$$H = g(x_1 * w_1, 1 + b_1)$$

$$H_{(1,1)} = sigmoid\ (g(x_1 * w_1, 1 + b_1))$$

$$= sigmoid\ ((0{,}183 * -0{,}51) + (0{,}149 * 0{,}73) + \text{------} + (0{,}88)))$$



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

= 0,399

$H_{(1,2)}$ = *sigmoid* $(g(x_2 * w_2, 1 + b_1))$

= *sigmoid* $((0{,}183 * -1{,}798) + (0{,}149 * -1{,}456) + \text{------} + (0{,}287)))$

= 0,312

$H_{(1,3)}$ = *sigmoid* $(g(x_3 * w_3, 1 + b_1))$

= *sigmoid* $((0{,}183 * -0{,}05) + (0{,}149 * 0{,}483) + \text{------} + (-1{,}64)))$

= *0,579*

Maka perhitungan diatas dibentuk dalam matriks *H* sampai mendapatkan data ke-72. Berikut kutipan matriks *H* yang diperoleh:

$$H = \begin{pmatrix} 0.39984875 & 0.31231203 & 0.57973195 & 0.08818999 & 0.82703313 \\ 0.430212 & 0.30937447 & 0.50958271 & 0.09395092 & 0.82368458 \\ 0.30809664 & 0.36410596 & 0.41945796 & 0.13978541 & 0.78550204 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0.3628232 & 0.28463236 & 0.55113859 & 0.07289721 & 0.87240917 \end{pmatrix}$$

Setelah mendapatkan hasil matriks *H* maka langkah selanjutnya menghitung nilai *bobot* menggunakan persamaan *2.14.* persamaan berikut adalah

$$\beta = H^T T$$

$$\beta = (H^T H)^{-1} H^T)T$$

Maka meperoleh hasil matriks $\beta$ (bobot) sebagai berikut :

$$\beta = [-1.22454516 \quad -1.97075204 \quad -0.25599063 \quad 1.7176785 \quad 3.93024392]^T$$

Setelah mendapatkan nilai bobot maka untuk langkah selanjutnya adalah proses *Testing data* yang dijelaskan di sub bab dibawah.

### 4.4.2. Prosedur Testing data

Untuk proses *testing* menggunakan data *testing* sebanyak 36 data¸ dimulai dari bulan january 2017 - desember 2019. Data yang sudah ada dihitung menggunakan matriks *H* dengan menggunakan bobot dan bias yang dihasilkan pada proses *training* dengan persamaan 2.10 untuk fungsi aktivasi yang digunakan



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

menggunakan rumus yang sama seperti di tahap *training* data yaitu menggunakan rumus aktivasi *sigmoid*. Berikut proses *testing data* di jelaskan pada tabel 4.11.

*Tabel 4. 11 Proses Testing data*

| |
|---|
| ***Proses testing data*** |
| *Start* |
| *Input inisialisasi bias and bobot* berasal dari proses *training* |
| Menghitung nilai matrik *hidden layer* menggunakan *fungsi aktivasi sigmoid ()* |
| *Proses feedforward ()* |
| *Output nilai Y.* |
| Selesai |

Pada tabel 4.10 di jelaskan proses untuk mengolah data dalam proses *testing* data dengan *Function* yang digunakan untuk tahap *testing* data di implementasikan ke dalam bahasa *python* berada pada tabel 4.12.

*Tabel 4. 12 Function Testing Data*

```
def predict(X,OutWeight,W,B):

    H   = hidden_nodes(X,W,B) #Activation hidden nodes

    out = np.dot(H,OutWeight) #Prediction Output

    return out
```

Dalam proses *testing*, *function* yang digunakan pertama mengidentifikasi dengan nama *predict* berisikan parameter *X* data yang digunakan untuk *testing*, *Outweight* adalah hasil bobot dari proses *training*, *W* untuk data *weight* dari *training*, dan *B* adalah nilai bias dari aktivasi *hidden nodes.* Menginisialisasi H untuk aktivasi nilai matriks dengan aktivasi sigmoid yang berisikan *function hidden_nodes* dengan parameter *X*, *W*, dan *B.* Kemudian inisial *out* untuk menghitung hasil dari peramalan pemakaian konsumsi listrik yang berisikan *library np.dot* untuk mengkalikan nilai matriks dari hasil nilai aktivasi H dikalikan dengan hasil nilai *OutWeight* atau hasil bobot dari proses *training.*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

Dibawah ini adalah proses manual dari perhitungan *testing*, matriks *H* diperoleh dari proses *testing* data yang berukuran 36 x 5.

$$H = \begin{pmatrix} 0.53316696 & 0.06331028 & 0.74863427 & 0.04598567 & 0.86104542 \\ 0.38611465 & 0.2356603 & 0.56777377 & 0.07744766 & 0.85420404 \\ 0.3674866 & 0.17646227 & 0.52656723 & 0.07468684 & 0.86430503 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0.41093234 & 0.23268391 & 0.62176066 & 0.05203544 & 0.89924044 \end{pmatrix}$$

Langkah berikutnya menghitung nilai *output (T)* yang menggunakan persamaan berikut ini *2.13* untuk nilai $\beta$ diperoleh dari proses *training* yang di *transpose.*

$$T = H\beta$$

$$\begin{pmatrix} 0.53316696 & 0.06331028 & 0.74863427 & 0.04598567 & 0.86104542 \\ 0.38611465 & 0.2356603 & 0.56777377 & 0.07744766 & 0.85420404 \\ 0.3674866 & 0.17646227 & 0.52656723 & 0.07468684 & 0.86430503 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0.41093234 & 0.23268391 & 0.62176066 & 0.05203544 & 0.89924044 \end{pmatrix} \begin{bmatrix} -1.22454516 \\ -1.97075204 \\ -0.25599063 \\ 1.7176785 \\ 3.93024392 \end{bmatrix}$$

Proses dari *testing data* yang dijelaskan pada gambar 3.5 seperti pada proses *training*, perbedaanya terletak pada proses *testing* hasil bias dan bobotnya diperoleh dari proses *training* dengan menghasilkan nilai target berikut ini :

$$T = \begin{bmatrix} -0.114175 \\ 0.127679 \\ 0.078851 \\ 0.054510 \\ 0.154975 \\ 0.168120 \\ 0.277851 \\ 0.333765 \\ 0.297048 \\ 0.356141 \\ 0.364712 \\ 0.273689 \end{bmatrix}$$

Nilai target yang diperoleh masih berupa angka kecil belum di denormalisasikan, setelah memperoleh nilai *Y*, langkah selanjutnya adalah melakukan proses uji validasi dengan *MSE* yang berguna untuk mengukur performa dari jaringan, melihat seberapa baik kemampuan untuk mengenali pola dan seberapa akurat digunakan untuk proses peramalan. Setelah melakukan uji *MSE* yaitu mengembalikan nilai ke bentuk aslinya atau *denormalisasi* dengan persamaan



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

2.3 untuk interval [0,1] dan di persamaan 2.4 untuk interval [-1,1] tujuannya agar nilai yang diperoleh mudah dipahami dengan data aslinya.

### 4.4.3. Pengujian Akurasi

Dalam pengujian validasi menggunakan uji *MSE (Mean Sequared Error)* dengan persamaan 2.17. Proses perhitungan *MSE* ditunjukkan pada tabel 4.13

*Tabel 4. 13 Proses Pengujian MSE*

| |
|---|
| ***Proses pengujian MSE*** |
| *Memasukkan data At (Data aktual/data target tahun 2019/yt_test) dan Ft (Data hasil peramalan/ prediction)* |
| *Data At (yt_test) dan Ft (prediction) dijumlahkan lalu dikuadratkan* |
| *Data At (yt_test) dan Ft (prediction) dibagi dengan jumlah periode t* |
| *Hasil* |

Pada tabel 4.13 digambarkan proses dari pengujian menggunakan *MSE*, kemudian untuk menghitung nilai *MSE* bisa di lihat pada *fuction* di tabel 4.14.

*Tabel 4. 14 Function uji MSE*

```
 #Calculate MSE #

  MSE[id] = np.square(np.subtract(yt_test[id],prediction[id])
).mean()

  MSEAll  = np.append(MSEAll,MSE[id])

  print('Hasil MSE id Pelanggan ',id,' : ',MSE[id],';')
```

*Library* yang digunakan yaitu *np.square* yang gunanya untuk menghitung nilai kuadrat, sedangkan untuk *np.subtract* digunakan untuk operasi bilangan pengurangan sedangkan Untuk *yt_test[id]* adalah nilai target dari id pelanggan dan *prediction [id]* adalah nilai *output* dari peramalan per pelanggan. Setelah proses *MSE* langkah selanjutnya mengembalikan nilai ke nilai aktual dengan cara *denormalisasi* berikut cara untuk *denormalisasi* pada sub bab dibawah ini.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

### 4.4.5. Denormalisasi

Pada tahap *denormalisasi* digunakan dengan tujuan mengembalikan data yang sudah di *normalisasi* ke dalam data aktual dengan menggunakan persamaan 2.3 karena normalisasi dari interval 0 hingga 1. Berikut adalah *function* untuk *denormalisasi* data disajikan pada tabel 4.15.

*Tabel 4. 15* Function Denormalisasi data

```
#Function Denormalization

def denormalisasi(x,a,b):

    y = (np.dot(np.subtract(x,0.1),(a-b))/0.8)+b

    return y
```

Langkah pertama untuk *denormalisasi data* yaitu mengidentifikasi nama *function* dengan nama *denormalisasi* yang terdiri dari parameter *x,a,b.* Dimana untuk *x* merupakan data yang akan di denormalisasi, sedangkan *a* merupakan data maksimum pada data set sebelum normalisasi sedangkan *b* adalah data minimum data set sebelum normalisasi. Setelah langkah - langkah diatas selesai maka langkah selanjutnya melakukan analisis. Untuk *source code* program dapat dilihat pada lampiran

## *4.5.* Hasil dan Analisis Peramalan Konsumsi Listrik Menggunakan Metode *Extreme Learning Machine.*

Dari proses perhitungan dengan algoritma ELM diperoleh hasil peramalan konsumsi listrik menggunakan uji validasi MSE dari program dengan persamaan 2.17. Percobaan peramalan *hidden layer* mengambil salah satu pelanggan R1 (Rumah tangga kecil) dengan ID 232010002504. Berikut hasil uji *MSE* nya pada tabel 4.16 berisikan jumlah *hidden layer*, nilai akurasi *MSE*, dan waktu yang dibutuhkan dalam proses *training.*

*Tabel 4. 16 Hasil prediksi listrik Pelanggan R1 menurut MSE*

| No | Hidden Layer | Nilai MSE | Waktu |
|---|---|---|---|
| 1 | 3 | 0,04653 | 9,59/s |
| 2 | 4 | 0,09664 | 9.15/s |
| 3 | 5 | 0,07420 | 9,64/s |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| No | Hidden Layer | Nilai MSE | Waktu |
|---|---|---|---|
| 4 | 6 | 0,03313 | 9,72/s |
| 5 | 7 | 0,05332 | 9,92/s |
| 6 | 8 | 0,07985 | 9,85/s |
| 7 | 9 | 0,07227 | 9,79/s |
| 8 | 10 | 0,06592 | 10,08/s |
| 9 | 11 | 0,06253 | 9,59/s |
| 10 | 12 | 0,06162 | 10,14/s |
| 11 | 13 | 0,05783 | 9,9/s |
| 12 | 14 | 0,04735 | 9,55/s |
| 13 | 15 | 0,05105 | 10,11/s |

Dari hasil peramalan untuk uji *MSE* sesuai dengan peryataan yang ada di kajian pustaka tentang ukuran kesalahan nilai *MSE,* bahwa semakin kecil nilai *MSE* yang didapat maka ramalan yang dilakukan semakin akurat. Sesuai dengan ketetapan dalam menentukan jumlah *hidden layer* yang ada di kajian pustaka, percobaan untuk awal memasukkan jumlah *hidden layer* adalah 3 *hidden layer* sampai dengan fungsi kinerja tidak sesuai dengan target *error* yang ditentukan yaitu 0,001.

Percobaan *hidden layer* dilakukan sampai *15* dikarenakan pada percobaan ke 15 terus mengalami peningkatan nilai, dan tidak memenuhi target *error* yang ditentukan. Untuk itu percobaan diberhentikan sampai ke 15. Maka di dapatkan nilai *MSE* terkecil adalah 0,03313 di percobaan *hidden layer* ke 6 dengan membutuhkan waktu untuk *training* 9,72 detik yang ditunjukkan pada tabel 4.16. Sehingga model terbaik dalam peramalan konsumsi listrik terletak pada percobaan *hidden layer ke 6.*

### 4.6. Evaluasi Hasil Pengujian

Dalam pemilihan jumlah *hidden layer* pada algoritma ELM. proses *testing* menghasilkan nilai *MSE* yang kecil sebesar 0,03313, dan jumlah *hidden layer* 6. Hal tersebut mendapatkan nilai bobot dan bias optimal karena menghasilkan nilai *MSE* mendekati 0. Setelah mendapatkan hasil *MSE* kecil maka hasil dari peramalan diuji keakurasian dengan data aktual. Hal tersebut digunakan untuk membuktikan



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

seberapa akurat dan layak algoritma yang di implementasikan. untuk perbandingan data asli dan data hasil ramalan disajikan pada tabel 4.17.

*Tabel 4. 17 Hasil peramalan konsumsi listrik dengan metode ELM*

| No | Bulan | Data Asli tahun 2019 | Hasil Ramalan |
|---|---|---|---|
| 1 | Januari tahun 2019 | 430 | 499 |
| 2 | Februari tahun 2019 | 551 | 468 |
| 3 | Maret tahun 2019 | 637 | 570 |
| 4 | April tahun 2019 | 663 | 632 |
| 5 | Mei tahun 2019 | 674 | 660 |
| 6 | Juni tahun 2019 | 595 | 691 |
| 7 | Juli tahun 2019 | 660 | 572 |
| 8 | Agustus tahun 2019 | 604 | 575 |
| 9 | September tahun 2019 | 557 | 554 |
| 10 | Oktober tahun 2019 | 506 | 510 |
| 11 | November tahun 2019 | 469 | 472 |
| 12 | Desember tahun 2019 | 522 | 476 |

Pada tabel 4.17 merupakan perbandingan antara data asli yang diramal dan data hasil peramalan pada tahun 2019. Untuk mengetahui perbedaan akurasinya menggunakan persamaan dibawah ini:

$$MAPE = \frac{1}{n}\sum_{t=1}^{n} \frac{Nilai\ error}{Data\ Actual} X\ 100\%$$

$$Nilai\ Error = nilai\ aktual - nilai\ peramalan$$

Hasil perhitungan untuk akurasi peramalan dan menentukan nilai *error* di tunjukkan pada tabel 4.18

*Tabel 4. 18 Hasil Perhitungan akurasi data asli dan data ramalan*

| No | Bulan | Data Asli tahun 2019 | Hasil Ramalan | Nilai \|*Error*\| | MAPE% |
|---|---|---|---|---|---|
| 1 | Januari tahun 2019 | 430 | 499 | 69 | 16,05% |



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

| No | Bulan | Data Asli tahun 2019 | Hasil Ramalan | Nilai \|*Error*\| | MAPE% |
|---|---|---|---|---|---|
| 2 | Februari tahun 2019 | 551 | 468 | 83 | 15,06% |
| 3 | Maret tahun 2019 | 637 | 570 | 67 | 10,52% |
| 4 | April tahun 2019 | 663 | 632 | 31 | 4,68% |
| 5 | Mei tahun 2019 | 674 | 660 | 14 | 2,08% |
| 6 | Juni tahun 2019 | 595 | 691 | 96 | 16,13% |
| 7 | Juli tahun 2019 | 660 | 572 | 88 | 13,33% |
| 8 | Agustus tahun 2019 | 604 | 575 | 29 | 4,80% |
| 9 | September tahun 2019 | 557 | 554 | 3 | 0,54% |
| 10 | Oktober tahun 2019 | 506 | 510 | 4 | 0,79% |
| 11 | November tahun 2019 | 469 | 472 | 3 | 0,64% |
| 12 | Desember tahun 2019 | 522 | 476 | 46 | 8,81% |
| | Total *MAPE* % | | | | 93,43/12 |
| | | | | | 7,79% |

Maka hasil akurasi antara data aktual dengan data hasil ramalan pada tahun 2019 didapatkan nilai MAPE 7.79%. sehingga dapat disimpulkan model yang dibangun dalam kinerja metode *extreme learning machine* baik digunakan untuk peramalan ke masa akan mendatang. Dilihat dari kriteria keakurasian data bahwa untuk < 10% merupakan peramalan sangat baik.

Hasil dari proses *testing* data aktual dan data peramalan disajikan dalam bentuk *plot* grafik di tunjukkan pada gambar 4.5.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

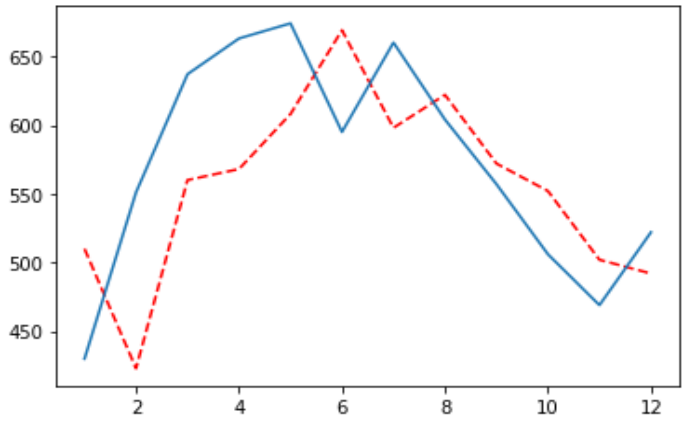


*Gambar 4. 5 plot grafik hasil proses testing data aktual dan data hasil*

Dari gambar tersebut untuk garis berwarna biru menunjukkan data aktual sedangkan untuk garis berwarna merah menunjukan data hasil peramalan. Dapat di ketahui Perbandingan untuk data aktual dan data hasil peramalan dalam metode ELM menghasilkan ramalan yang baik. Hal tersebut diperkuat dengan hasil akurasi berada pada tabel 4.17 dan hasil grafik pada gambar 4.5



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# BAB V
# PENUTUP

Melihat dari hasil analisis dan pengujian yang sudah dilakukan, maka dapat di tarik kesimpulan dan saran sebagai berikut :

## 5.1. Kesimpulan

1. Metode *extreme learning machine* dapat diterapkan dalam peramalan konsumsi listrik pelanggan perbulan ditunjukkan dengan pengujian pada hasil peramalan yang sudah dilakukan dan mendapatkan nilai akurasi yang kecil.
2. Hasil peramalan konsumsi listrik yang digunakan dengan metode *extreme learning machine* pada pelanggan mendapatkan tingkat akurasi *MSE* sebesar 0,03313. Dan untuk perbandingan data hasil peramalan dengan data aktual di peroleh tingkat akurasi *MAPE* 7,79% dimana dalam kriteria *MAPE* data untuk akurasi kurang dari 10% dikatakan peramalan sangat baik dapat disimpulkan bahwa peramalan yang dilakukan dapat dijadikan pengambilan keputusan dalam merencanakan penyediaan konsumsi listrik dimasa akan datang.

## 5.2. Saran

1. Untuk penelitian mendatang perlu untuk membandingkan dengan metode peramalan lainnya.
2. Data pemakaian konsumsi listrik untuk peramalan lebih di perbanyak dan menambahkan beberapa kelompok kategori tarif agar pihak perusahaan dapat lebih mudah mengambil keputusan dalam perencanaan penyediaan.
3. Perlu mengimplementasikannya kedalam sebuah sistem WEB agar dapat mepermudah dalam *forcasting*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

# DAFTAR PUSTAKA

Agustina, I. D., Anggraeni, W. and Mukhlason, A. (2005) 'Penerapan Metode Extreme Learning Machine untuk Peramalan Permintaan', *Digilib, Institut Teknologi Sepuluh Nopember*, pp. 1–6.

Aji, C. S. (2010) 'Faktor-Faktor Yang Mempengaruhi Konsumsi Listrik PLN Pada Kelompok Pelanggan Rumah Tangga ( R-1 900 VA ) di Kabupaten Purworejo Tahun 2002-2008'.

Bisnis, D. S. and Vokasi, F. (2017) 'BERDASARKAN PEMAKAIAN KWH UNTUK KATEGORI INDUSTRI I-4 DI PT . PLN DISTRIBUSI TIMUR MENGGUNAKAN ARIMA BOX-JENKINS BERDASARKAN PEMAKAIAN KWH UNTUK KATEGORI INDUSTRI I-4 DI PT PLN ( PERSERO ) DISTRIBUSI JAWA TIMUR MENGGUNAKAN'.

F., A., Elsir, S. and Faris, H. (2015) 'A Comparison between Regression, Artificial Neural Networks and Support Vector Machines for Predicting Stock Market Index', *International Journal of Advanced Research in Artificial Intelligence*, 4(7). doi: 10.14569/ijarai.2015.040710.

Fikriya, Z. A. *et al.* (2017) '928X Print) A 18', *Jurnal Sains dan Seni ITS*, 6(1).

Hadijah (2014) *Analisis Faktor-faktor yang Mempengaruhi Permintaan Daya Listrik Rumah Tangga di Kabupaten Soppeng, Fakultas Ekonomi dan Bisnis UIN Alauddin Makassar*.

Huang, G. Bin, Zhu, Q. Y. and Siew, C. K. (2004) 'Extreme learning machine: A new learning scheme of feedforward neural networks', *IEEE International Conference on Neural Networks - Conference Proceedings*, 2(August), pp. 985–990. doi: 10.1109/IJCNN.2004.1380068.

Huang, G., Zhu, Q. and Siew, C. (2004) 'Extreme Learning Machine : A New Learning Scheme of Feedforward Neural Networks', (August). doi: 10.1109/IJCNN.2004.1380068.

Huang, Gao *et al.* (2015) 'Trends in extreme learning machines: A review', *Neural Networks*. Elsevier Ltd, 61(October 2017), pp. 32–48. doi:



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

10.1016/j.neunet.2014.10.001.

Humaini, Q. (2015) 'Jaringan Syaraf Tiruan Extreme Learning Machine ( Elm ) Untuk Memprediksi Kondisi Cuaca', pp. 1–86.

Ilmiyah, M. (2018) 'Aplikasi metode Seasonal Autoregressive Integrated Moving Average dan Winter's Exponential Smooting untuk meramalkan omzet koperasi Al-Kautsar Universitas …'. Available at: http://digilib.uinsby.ac.id/26732/.

Indonesia, U. *et al.* (2012) 'Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditional Heteroskedasticity ( Garch ) Metode Generalized Autoregressive Conditional'.

Jaskolka, K. *et al.* (2019) 'A Python-based laboratory course for image and video signal processing on embedded systems', *Heliyon*, 5(10). doi: 10.1016/j.heliyon.2019.e02560.

Jayanti, H. D., Cholissodin, I. and Santoso, E. (2018) 'Peramalan Pemakaian Air Pada PLTGU Di Pembangkitan Listrik Jawa Bali Unit Gresik Menggunakan Extreme Learning Machine Dengan Optimasi Algoritme Genetika', *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 2(11), pp. 4895–4904.

Jeno, G., Dengen, N. and Budiman, E. (2019) 'Aplikasi Manajemen Stok Barang Pada Usaha Kecil Menengah Kebab Inidia Berbasis Web', 4(1), pp. 16–19.

Kementerian ESDM (2020) 'Tarif Dasar Listrik 2020', pp. 11–13. Available at: https://www.cekaja.com/info/daftar-tarif-dasar-listrik-terbaru-2020-beserta-rumus-penghitungannya/.

Khotimah, B. K., Sari R, E. M. and Yulianarta, H. (2010) 'Kinerja metode extreme learning machine (elm) pada sistem peramalan *', *Jurnal Simantec*, 1(3), pp. 186–191.

Liang, Y. *et al.* (2016) 'Analysis and Modeling for China ' s Electricity Demand Forecasting Using a Hybrid Method Based on Multiple Regression and Extreme Learning Machine : A View from Carbon Emission', pp. 1–22. doi: 10.3390/en9110941.



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

Makalesi, A., Aydın, D. and Toros, H. (2018) 'Prediction of Short-Term Electricity Consumption by Artificial Neural Networks Using Temperature Variables', *European Journal of Science and Technology*, (14), pp. 393–398. doi: 10.31590.

Mardi, Y. (2017) 'Data Mining : Klasifikasi Menggunakan Algoritma C4.5', *Jurnal Edik Informatika*, 2(2), pp. 213–219.

Meilia, V., Setiawan, B. D. and Santoso, N. (2018) 'Optimasi Bobot pada Extreme Learning Machine untuk Prediksi Beban Listrik menggunakan Algoritme Genetika ( Studi Kasus : PT . PLN ( Persero ) APD Kalsel dan Kalteng )', *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 2(11), pp. 4949–4956.

Muslimin (2015) 'Peramalan Beban Listrik Jangka Menengah Pada Sistem Kelistrikan Kota Samarinda', *Jiti*, 14(09), pp. 113–121.

Nababan, T. S. (2008) 'Permintaan Energi Listrik Rumah Tangga (Studi Kasus pada Pengguna Kelompok Rumah Tangga Listrik PT PLN (Persero) di Kota Medan)', *Universitas Diponegoro*, p. 232.

Prakoso, E. C., Wisesty, U. N. and . J. (2016) 'Klasifikasi Keadaan Mata Berdasarkan sinyal EEG menggunakan Extreme Learning Machines', *Indonesian Journal on Computing (Indo-JC)*, 1(2), p. 97. doi: 10.21108/indojc.2016.1.2.105.

Purnama, R., Setiawan, A. A. and Suhanan, S. (2017) 'Perkiraan Konsumsi Energi Listrik 2013 Hingga 2030 Aceh Tamiang', *Angkasa: Jurnal Ilmiah Bidang Teknologi*, 7(2), p. 85. doi: 10.28989/angkasa.v7i2.152.

Puspita, V. (2017) 'Time Series untuk Peramalan Konsumsi Listrik Menggunakan Metode Support Vector Machine ( SVM )', 3(1), pp. 261–264.

Rachman, A. S., Cholissodin, I. and Fauzi, M. A. (2018) 'Peramalan Produksi Gula Menggunakan Metode Jaringan Syaraf Tiruan', *Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(4), pp. 1683–1689. Available at: https://www.researchgate.net/publication/322963136.

Radjabaycolle, J. and Pulungan, R. (2016) 'Prediksi Penggunaan Bandwidth Menggunakan Elman Recurrent Neural Network', *BAREKENG: Jurnal Ilmu*



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

*Matematika dan Terapan*, 10(2), pp. 127–135. doi: 10.30598/barekengvol10iss2pp127-135.

Rahmadayanti, R., Susilo, B. and Puspitaningrum, D. (2015) 'Perbandingan Keakuratan Metode Autoregressive Integrated Moving Average (Arima) dan Exponential Smoothing pada Peramalan Penjualan Semen di PT Sinar Abadi', *Jurnal Rekursif*, 3(1), pp. 23–36.

Ruliah, S. and Rolyadely, R. (2012) 'Prediksi Pemakaian Listrik Dengan Pendekatan Back Propagation', pp. 465–476.

Rumagit, S. and SN, A. (2013) 'Prediksi Pemakaian Listrik Menggunakan Jaringan Syaraf Tiruan dan ARIMA Di Wilayah Sulluttenggo', *Bimipa*, 23(2), pp. 139–148.

Sari, N. R., Mahmudy, W. F. and Wibawa, A. P. (2016) 'Backpropagation on neural network method for inflation rate forecasting in Indonesia', *International Journal of Advances in Soft Computing and its Applications*, 8(3), pp. 69–87.

Schikuta, E. (2008) 'Neural Networks and Database Systems'. Available at: http://arxiv.org/abs/0802.3582.

Sel, I. (1940) 'Iruan 8', pp. 149–204.

Sri Kusumadewi (2003) 'Rtificial Ntelligence', *Artificial Intelligence (Teknik dan Aplikasinya*.

Vanich Sajee (2015) 'Data Mining: Data Mining (เหมืองข้อมูล)', *2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)*, 2(1), pp. 267–274. Available at: http://sajeegm301.blogspot.com/2015/11/data-mining.html.

Yoo, S. G. and Myriam, H. Á. (2018) 'Predicting residential electricity consumption using neural networks: A case study', *Journal of Physics: Conference Series*, 1072(1). doi: 10.1088/1742-6596/1072/1/012005.

Yuwida, N., Hanafi, L. and Wahyuningsih, N. (2012) 'Estimasi Parameter α dan ϒ Dalam Pemulusan Eksponensial Ganda Dua Parameter Dengan Metode Modifikasi Golden Section', *Jurnal Sains dan Seni ITS*, 1(1).



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id

CNN INDONESIA, 2017, Penjualan listrik pln anjlok drastis di kuartal di https://www.cnnindonesia.com/ekonomi/20170410123010-92-206268/penjualan-listrik-pln-anjlok-drastis-di-kuartal-i-2017, (Diakses pada tanggal 30 Maret)

Bps Indonesia, 2018, proyeksi penduduk kota balikpapan menurut kecamatan tahun 2010-2017, di https://balikpapankota.bps.go.id/statictable/2018/01/19/54/proyeksi-penduduk-kota-balikpapan-menurut-kecamatan-tahun-2010-2017.html , (Diakses pada tanggal 30 Maret)

Tafsir WEB, quran surah al-isra ayat 27 di https://tafsirweb.com/4631-quran-surat-al-isra-ayat-27.html (diakses 4 April)



digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id digilib.uinsby.ac.id