

PREDIKSI PENGGUNAAN ENERGI LISTRIK DENGAN MENGGUNAKAN METODE OPTIMALLY PRUNED EXTREME LEARNING MACHINE

PREDICTION OF ELECTRICITY USING OPTIMALLY PRUNED EXTREME LEARNING MACHINE METHOD

Aldio Rahardian¹, Casie Setianingsih², Muhammad Ary Murti³

^{1,2,3} Universitas Telkom, Bandung

¹aldiorahardian@student.telkomuniversity.ac.id, ²setiacasie@telkomuniversity.ac.id,

³arymurti@telkomuniversity.ac.id

Abstrak

Peramalan adalah perkiraan atau proses perhitungan dengan menggunakan data pada masa lalu dan menggunakannya sebagai proses belajar untuk masa depan. Peramalan beban listrik ini merupakan faktor dalam perencanaan pengoperasian tenaga listrik agar masyarakat dapat lebih bisa mengetahui atau transparansi pada perhitungan biaya listrik secara berkala. Untuk melakukan prediksi kebutuhan energi listrik membutuhkan beberapa metode dan tidak mudah, prediksi beban energi listrik ini sangatlah dibutuhkan bagi perusahaan agar pengelolaan energi listrik di perusahaan tersebut dapat optimal dan memudahkan perusahaan tersebut melihat kenaikan beban listrik pada perusahaan tersebut. Dalam memprediksi penggunaan energi listrik ini digunakan metode Optimally pruned extreme learning machine (OPELM) sebagai model yang bisa diterapkan. Untuk membuat dan mengimplementasikan metode Optimally pruned extreme learning machine ada beberapa data yang dibutuhkan seperti data penggunaan jumlah energi listrik selama beberapa bulan kebelakang. Untuk itu pada penelitian ini digunakan metode Optimally pruned extreme learning machine (OPELM) untuk menjadi solusi yang optimal dengan menggunakan dua tahap perhitungan dari metode OPELM. OPELM mempunyai kelebihan yaitu pada proses pembelajaran, pembelajaran pada OPELM ini termasuk cepat dan pemilihan model yang tepat. Hasil dari penelitian menggunakan pengujian keakuratan Average Mean Absolute Error (MAE) dengan nilai 0,14935 dan Average Mean Square Error (MSE) dengan nilai 0,08034.

Kata Kunci: Peramalan Beban Listrik Jangka Panjang, OPELM, ELM Peramalan, Jaringan Saraf Tiruan.

Abstract

Forecasting is an estimate or calculation process by using data in the past and using it as a learning process for the future. Electricity load forecasting is a factor in the planning of electricity operations so that the public can better know or transparency on the calculation of electricity costs periodically. To predict the need for electricity needs require several methods and not easy, this prediction of electricity energy load is needed for the company so that the management of electric energy in the company can be optimal and make it easier for the company to see the increase in electricity load on the company. In predicting the use of electrical energy is used optimally pruned extreme learning machine (OPELM) method as a model that can be applied. To create and implement optimally pruned extreme learning machine method there are some data needed such as data usage of the amount of electrical energy over the past few months. Therefore, in this study, optimally pruned extreme learning machine (OPELM) method was used to become the optimal solution by using two stages of calculation of OPELM method. OPELM has the advantage of learning, learning in OPELM is included quickly and the selection of the right model. The results of the study used an Average Mean Absolute Error (MAE) accuracy test with a value of 0.14935 and an Average Mean Square Error (MSE) with a value of 0.08034.

Keywords: Long Term Electric Load Forecasting, OPELM, ELM Forecasting, Artificial Neural Network

1. Pendahuluan

Pada saat ini sumber daya listrik merupakan sumber energi yang paling banyak digunakan dan menjadi salah satu sumber energi yang dibutuhkan bagi peralatan elektronik untuk memenuhi kebutuhan sehari-hari. Untuk mengetahui jumlah pemakaian listrik, PLN selaku institusi yang memfasilitasi listrik bagi pelanggan menggunakan sebuah alat yang biasa disebut dengan kWh meter, kWh meter merupakan alat yang digunakan untuk mengukur daya listrik, yang biasa digunakan oleh rumah tangga adalah kWh meter berbentuk analog, selain analog ada juga kWh meter digital yang merupakan teknologi yang lebih efektif dan efisien. Untuk melihat konsumsi pemakaian listrik PLN masih menggunakan metode rumah ke rumah (pada kWh meter analog), namun untuk penggunaan (AMR), Automated Meter Readings pemantauan konsumsi hanya bisa dilihat dari alat tersebut, dari 2 alat pengukur di atas hanya bisa melihat di penggunaan bulan itu saja dan jumlah pemakaian di bulan itu saja.

Sehubungan meningkatnya perkembangan machine learning dan kecerdasan buatan di dunia maka kedua hal tersebut bisa digunakan dan dijadikan solusi untuk melakukan penelitian untuk mengukur kWh meter dalam kurun waktu beberapa bulan ke depan dengan menggunakan metode prediksi atau forecasting. Dengan menggunakan metode ini diharapkan bisa membantu memantau atau mengukur kenaikan atau penurunan biaya listrik dan bisa menyajikannya

dalam bentuk grafik dan tabel. Website ini bisa menjadi catatan pengelolaan penggunaan energi listrik agar lebih terkendali dan dapat diukur dan diprediksi agar masyarakat dapat memilih kebijakan pengeluaran untuk melakukan penghematan atau tidak sesuai dengan hasil dari website.

2. Landasan Teori

2.1 Peramalan

Peramalan adalah sebuah kebutuhan pemikiran dimasa yang akan datang dan peramalan ini berperan sangat penting bagi kehidupan, banyak metode yang digunakan pada metode peramalan. Salah satunya adalah metode Optimally pruned extreme learning machine (OPELM). Salah satu cara peramalan bekerja adalah dengan cara melakukan training dan data uji coba dan data tersebut kemudian diolah dan di uji dengan data testing. Peramalan kuantitatif adalah metode peramalan yang menggunakan data data khusus atau tertentu sebagai datasetnya.

2.2 kiloWatt Hour (kWh)

Kilo Watt Hour sebuah alat untuk memberikan perhitungan energi yang masih aktif, kWh meter juga berfungsi untuk menghitung jumlah kerja listrik (Watt jam) dalam kisaran waktu tertentu. Cara kerja alat perhitungan kWh meter ini adalah mengubah sejumlah kerja listrik ke dalam bentuk energi mekanis untuk menggerakkan roda perputaran jumlah angka agar jumlah kerja listrik yang digunakan beban sama. Alat ukur kWh meter ini juga menunjukkan bilangannya menggunakan jarum [1].

2.3 Karakteristik Beban Listrik

Pada kegiatan konsumen listrik dapat dikelompokkan menjadi beberapa konsumen seperti, konsumen komersil, konsumen rumah tangga, konsumen publik, dan konsumen industri [2]. Penting sekali ketika untuk melakukan prediksi ini dan harus melakukan analisis pola dan karakteristik pada tiap-tiap konsumen. Informasi yang didapat juga diperoleh dari beberapa jenis konsumen tersebut untuk mengetahui besar daya yang digunakan dan waktu pembebanannya. Dalam proses peramalan energi listrik juga banyak istilah istilah yang harus dikenal sebagai dasar pertimbangan untuk menilai beban yang dibutuhkan [3].

1. Kebutuhan (demand)

Adalah beban rata rata pada interval waktu tertentu. Interval waktu tersebut dapat menunjukkan besarnya beban yang nantinya akan ditentukan yang disebut demand interval [4].

2. Beban puncak (peak load)

Beban tertinggi yang terjadi selama beberapa periode tertentu, misal beban listrik harian, beban listrik bulanan, dan beban listrik tahunan [4].

2.4 Jaringan Saraf Tiruan

Jaringan Syaraf Tiruan atau artificial neural network adalah sebuah jaringan syaraf yang merupakan bentuk dari struktur syaraf otak. Dengan berdasarkan pengalaman dan pengamatan kejadian yang lalu maupun sekarang, otak bekerja dari pengalaman. Bagian dari jaringan syaraf otak yang berfungsi untuk mengirim data dari satu titik ke titik yang lain adalah neuron. Neuron adalah sebuah unit dari pengolahan sinyal. Otak mampu untuk menerima beberapa sinyal masukan dan dapat mengenali pola dengan kapasitas memori yang sangat besar, otak juga dapat melakukan perhitungan dengan kecepatan respon yang cukup tinggi dan dapat memberikan respon ke organ organ tubuh [5]. Beberapa komponen otak sama pentingnya dengan neuron hanya saja fungsi dari neuron ini adalah fungsi yang paling vital untuk mengambil keputusan. Seperti dendrit yang dapat menerima sinyal dan menyambungkan antara neuron dengan neuron lainnya, kemudian sinyal dapat masuk ke soma untuk mengaktifkan sinyal sinyal yang masuk. Pada bagian sinapsis otak dapat memiliki batas sinyal (threshold) dimana pada bagian ini sebagai penguat atau pelemah sinyal[5].

2.5 Optimally Pruned Extreme Learning Machine

Optimally Pruned Extreme Learning Machine (OPELM) merupakan sebuah metode hasil dari pembaruan atau inovasi dari metode Extreme Learning Machine (ELM). OPELM diciptakan untuk memperbaiki konsep dari ELM yang menjadi kelemahan pada ELM terdapat suatu variabel yang tidak relevan atau tidak berkorelasi [6]. Metode Optimally Pruned Extreme Learning Machine (OPELM) dibuat untuk memaksimalkan algoritma dari Extreme Learning Machine dengan juga memaksimalkan parameter yang ada. Metode OPELM ini sangat optimal karena parameter pada metode ini bisa dikalibrasi sesuai dengan bentuk datanya dan proses pembelajaran sangat cepat dan tidak membutuhkan waktu yang sangat panjang. Terdapat dua tahapan penting pada model OPELM ini [6]. Pada algoritma OPELM ini menggunakan dua jenis kernel yang berbeda, agar hasil yang didapat itu tidak terdapat variabel yang nantinya tidak akan berkorelasi. Kernel yang digunakan adalah kernel sigmoid dan gaussian.

1. Langkah pertama adalah membangun struktur SLFN (Single Hidden Layer Feedforward Neural Network) menggunakan algoritma ELM (Extreme Learning Machine).
2. Langkah kedua adalah Kalibrasi beberapa parameter untuk menjadi acuan pembelajaran mesin agar hasil yang didapat maksimal.

2.5.1 Normalisasi

Sebelum dapat dilakukan proses pembagian data *training* dan *testing* dataset harus di normalisasi terlebih dahulu, *output* dari normalisasi ini akan dapat menghasilkan angka *range* dari [0; 1]. Normalisasi yang digunakan adalah dengan metode *Min-Max Normalization* dengan persamaan sebagai berikut [7]:

$$X = \frac{(x_p - \min x_p)}{(\max x_p - \min x_p)} \quad (2.1)$$

2.5.2 Pipeline

pipeline disini berfungsi untuk merangkum dan mengotomatiskan semua parameter agar dapat melakukan pengujian model dengan parameter yang dimasukkan.

2.5.3 Denormalisasi

Sesudah dilakukan proses *machine learning* nilai yang dinormalisasi tadi harus dikembalikan menjadi nilai yang sebenarnya kembali agar menjadi nilai data yang sebenarnya dengan persamaan sebagai berikut [7]:

$$X = (x'(max - min)) + min \quad (2.2)$$

2.5.4 Pembentukan *Extreme Learning Machine*

Langkah selanjutnya yang harus diterapkan dalam metode *Optimally Pruned Extreme Learning Machine* adalah menggunakan awal penerapan dari *Extreme Learning Machine* dengan karakteristik neuron yang besar (*Neuron hidden*). Proses penerapan *Extreme Learning Machine* dimulai dari menentukan *hidden layer* seperti persamaan berikut ini dengan fungsi aktivasi sigmoid [7]:

$$H = \frac{1}{(1 + (X_{train} \times W) + b)} \quad (2.3)$$

Selanjutnya adalah perkalian *hidden layer*, persamaan sebagai berikut [7]:

$$H^+ = (H^T \cdot H)^{-1} \times H^T \quad (2.4)$$

Proses selanjutnya adalah menghitung nilai *output weights* yang telah diperoleh dari hasil perkalian *hidden layer*, persamaan sebagai berikut [7]:

$$\beta = H^+ \times \gamma \quad (2.5)$$

Metode *Optimally Pruned Extreme Learning Machine* menggunakan awal penerapan dari *Extreme Learning Machine* dengan karakteristik neuron yang besar (*Neuron hidden*) [8].

2.5.6 Kalibrasi

Langkah selanjutnya yang harus ditetapkan adalah kalibrasi parameter agar data yang akan di prediksi dapat mengeluarkan hasil yang optimal dan yang terbaik. Adapun beberapa parameter yang harus di kalibrasi adalah:

1. *Neuron hidden* adalah bagian dari *hidden layer* yang dapat digunakan sewajarnya karena hasilnya agar dapat optimal jika dipakai [9].
2. *Alpha* parameter yang sering disebut *learning rate* untuk menentukan hasil yang diinginkan dari model.
3. *Radial basis function width* sebuah sistem kernel hanya saja memakai lebar dari function untuk proses *extreme learning machine* [10].
4. *Activation function* adalah sistem kernel, pada sistem OPELM kernel yang dipakai ada dua yaitu gaussian dan sigmoid.
5. *Ridge alpha* puncak dari parameter learning rate [10].

2.6 Fungsi Aktivasi

Fungsi aktivasi ini yang bertujuan untuk menghitung berapa output yang ingin dikeluarkan tidak peduli berapa banyak lapisan yang dimiliki jaringan syaraf tiruan. Fungsi aktivasi ini yang bergerak sebagai kesimpulan apakah neuron harus diaktifkan atau neuron tidak diaktifkan [10]. Pada lapisan output menyajikan hasil dari fungsi aktivasi yang telah dikontrol oleh fungsi aktivasi untuk melakukan klasifikasi, prediksi dan probabilitas. Posisi fungsi aktivasi ini sangat bergantung pada fungsinya dalam jaringan, ketika fungsi aktivasi ditempatkan setelah lapisan hidden layer ini pasti mengubah peran dari fungsi aktivasi dan hasilnya akan menjadi bentuk non-linier untuk outputnya [11]. Fungsi


aktivasi yang dipakai pada tugas akhir ini adalah Sigmoid dan Gaussian sebagai pembanding nilai mana yang mencapai nilai akurasi terkecil [12]. Persamaan sigmoid seperti berikut:

$$H = \frac{1}{(1+(x_{train} \times W)+b)} \tag{2.6}$$

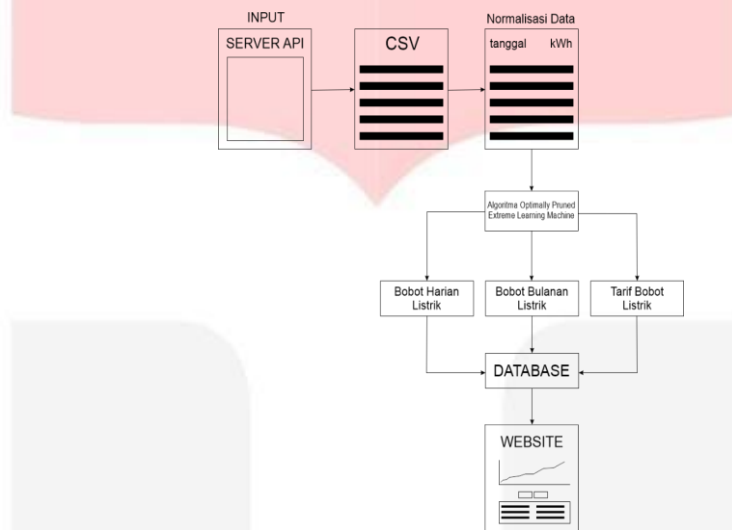
3. Perancangan

3.1 Gambaran Umum Sistem

Untuk perancangan model yang dibangun secara umum sistem yang akan dibangun seperti gambar berikut:



Gambar 3.1 Gambaran Umum Proses Sistem yang Akan Dibuat



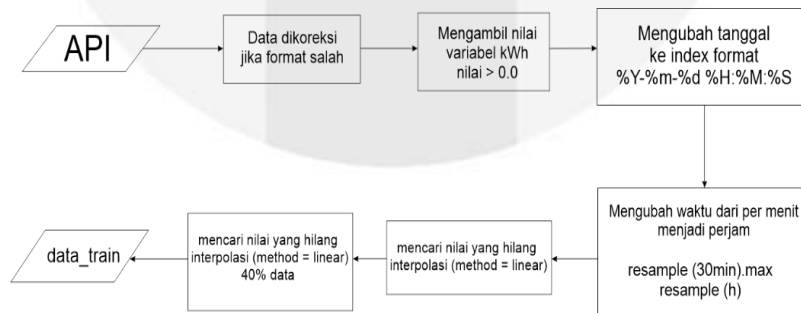
Gambar 3.2 Model Pengolahan Data di Sistem yang Akan Dibuat

3.2 Perancangan Struktur *Optimally Pruned Extreme Learning Machine*

Terdapat beberapa tahapan perancangan struktur dari sistem Machine Learning dan Optimally Pruned Extreme Learning Machine, dimulai dari tahap *preprocessing*, *machine learning*, dan *output*.

3.2.1 *Preprocessing*

Tahap *preprocessing* berfungsi untuk memaksimalkan data yang akan digunakan untuk melakukan proses *forecasting* pada *machine learning*.

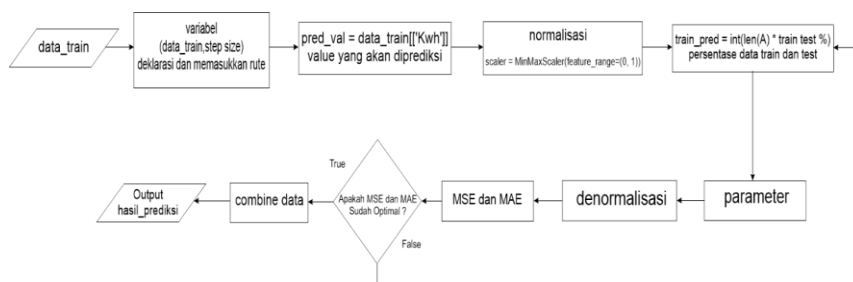


Gambar 3.3 Diagram Alir Sistem Preprocessing

$$\text{Interpolasi Linier: } \frac{(x-x_1)}{(x_2-x_1)} = \frac{(y-y_1)}{(y_2-y_1)} \tag{3.1}$$

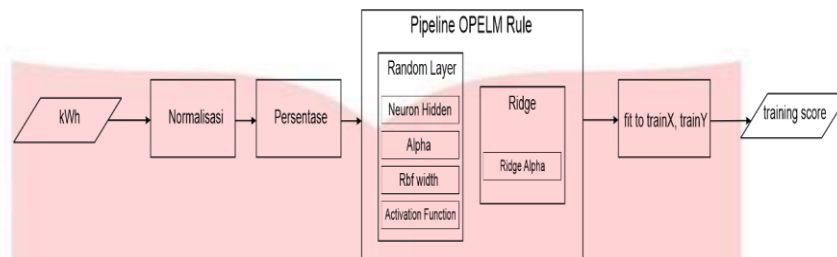
3.2.2 Optimally Pruned Extreme Learning Machine

Tahap machine learning untuk melakukan proses forecasting dan melakukan proses pembelajaran.



Gambar 3.4 Diagram Alir OPELM


3.2.3 Arsitektur Pada Optimally Pruned Extreme Learning Machine



Gambar 3.5 Diagram Alir Arsitektur OPELM

3.2.4 Sistem Pembagian Nilai Perhari dan Perbulan

Ketika sudah melalui tahap proses *machine learning* tahap selanjutnya adalah proses pada hasil dari *machine learning* yang terdapat dua *output* yaitu data perhari dan data perbulan.

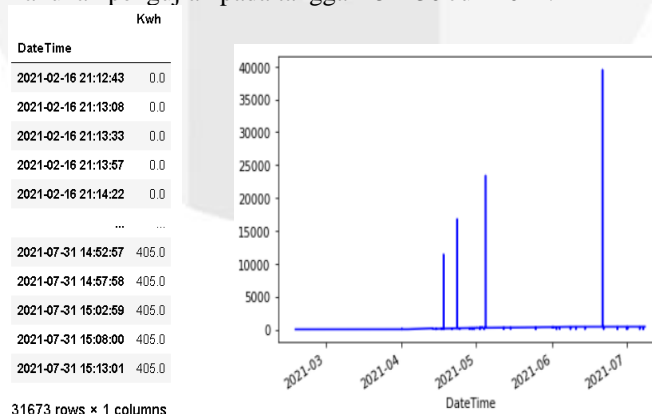


Gambar 3.6 Diagram Alir Output

4. Implementasi dan Pengujian

4.1 Pengumpulan Dataset

Data yang digunakan untuk dikelola oleh model machine learning adalah data dari gedung deli Fakultas Teknik Elektro pada device 5 dengan rentang data dari bulan Februari sampai Agustus sebanyak dari hasil pengujian 28.779 data sampai 31.673 data. Dilakukan pengujian pada tanggal 15 – 30 Juli 2021.



Gambar 4.1 Dataset Pengujian

4.2 Pengujian Performansi Partisi Data

pengujian algoritma ini dicoba beberapa parameter *machine learning* pada metode *Optimally Pruned Extreme Learning Machine* untuk dicari nilai optimal dari beberapa parameter yang ada. Mencoba sample sebanyak lima nilai berbeda pada setiap parameter yang diuji. Pembagian data *train* dan *test* diperlukan untuk mencari nilai persentase pembelajaran yang optimal yang berguna untuk mendapatkan hasil keluaran *output* yang semaksimal mungkin.

Tabel 4.1 AVG MSE dan AVG MAE Sigmoid Gaussian

Persentase	Sigmoid		Gaussian		
	Train : Test	AVG MSE	AVG MAE	AVG MSE	AVG MAE
50 : 50		0,13817	0,62860	0,18442	0,89034
60 : 40		0,13822	0,21660	0,16211	0,23895
70 : 30		0,13691	0,21731	0,14518	0,23718
80 : 20		0,13472	0,21407	0,13422	0,23006
89 : 11		0,13425	0,21202	0,13364	0,21709

4.3 Pengujian Parameter Kalibrasi

Untuk menguji dan mencari parameter yang optimal dengan menggunakan data train sebesar 89% dan data test sebesar 11% ada beberapa parameter yang harus dicari nilai yang optimal dengan cara menerapkan beberapa kali perubahan parameter.

4.3.1 Neuron Hidden

Tabel 4.2 AVG MSE dan AVG MAE Neuron Hidden

Neuron Hidden										
Train Test	50		100		150		200		250	
	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE
89 % :11%	0,13564	0,21748	0,13445	0,21564	0,13430	0,21296	0,13417	0,21202	0,13403	0,21143

Parameter neuron hidden yang dipakai adalah 250, dengan nilai MSE 0,13403 dan MAE 0,21143.

4.3.2 Alpha

Tabel 4.3 AVG MSE dan AVG MAE Alpha

Alpha										
Train Test	0,2		0,4		0,6		0,8		1,0	
	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE
89 % :11%	0,26524	0,69173	0,16647	0,49207	0,13180	0,37465	0,07848	0,22885	0,13377	0,21199

Parameter alpha yang dipakai adalah 0.8, dengan nilai MSE 0,07848 dan MAE 0,22885. Karena nilai selisih dari alpha termasuk yang paling kecil jika dibandingkan dengan nilai alpha yang lain.

4.3.3 Rbf width

Tabel 4.4 AVG MSE dan AVG MAE Rbf width

Rbf width										
Train Test	0,2		0,4		0,6		0,8		1,0	
	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE
89 % :11%	0,13370	0,17237	0,13358	0,17129	0,08186	0,14373	0,08101	0,14686	0,07215	0,13750

Parameter rbf width yang dipakai adalah 1,0 ,dengan nilai MSE 0,07215 dan MAE 0,13750. Karena nilai 1,0 adalah nilai yang paling optimal dari nilai rbf width yang lainnya.

4.3.4 Ridge Alpha

Tabel 4.5 AVG MSE dan AVG MAE Ridge Alpha

Ridge Alpha										
Train Test	0,002		0,004		0,006		0,008		0,0010	
	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE	AVG MSE	AVG MAE
89 % :11%	0,08823	0,15637	0,10146	0,16800	0,10652	0,17314	0,11684	0,16264	0,11684	0,12465

Parameter ridge alpha yang dipakai adalah 0,002 ,dengan nilai MSE 0,08823 dan MAE 0,15637. Karena nilai 0,002 adalah nilai yang paling optimal dari nilai ridge alpha yang lainnya.

4.4 Parameter Optimal

Berdasarkan hasil uji parameter yang sudah dilakukan dan didapatkan data parameter yang optimal yaitu parameter dengan nilai MAE dan MSE terkecil atau nilai parameter dengan selisih nilai kecil dari nilai yang lain maka didapatkan parameter:


1. Neuron hidden = 250
2. Alpha = 0,8
3. Rbf width = 1,0
4. Ridge Alpha = 0.002
5. Data train dan test = 89 % dan 11 %
6. Fungsi aktivasi = Sigmoid

Tabel 4.6 Parameter Optimal


Parameter Optimal		
Train Test	Sigmoid	
	AVG MSE	AVG MAE
89 % :11%	0,08034	0,14935

4.4.1 Hasil Output Parameter Optimal

Dari hasil uji parameter kemudian parameter tersebut di terapkan kedalam hasil prediksi dan hasil yang didapatkan berupa grafik , dibawah ini terdapat dua grafik pada gambar 4.2 adalah grafik ketika proses machine learning peramalan belajar atau proses data train dari data masuk sehingga bentuk grafik terlihat baik karena hasil belajar yaitu hasil test nya. Di gambar 4.3 ketika proses menggabungkan data hasil prediksi untuk mendapatkan nilai future value yang akan digunakan untuk melakukan proses peramalan data perhari, data perbulan, dan tarif yang akan dikeluarkan pada nilai future value.



Gambar 4.2 Hasil Data Test



Gambar 4.3 Data Combine

Tabel 4.7 Tabel Hasil Data Test MAE dan MSE

No	Nilai Real	Nilai Real Prediksi	$ A_i - F_i $
1	248	248,496	-0,469
2	248	248,496	-0,469
3	248	248,496	-0,469
4	405	404,727	0,273
5	406	404,727	1,273
6	406	405,564	0,436
MAE			0,082

No	Nilai Real	Nilai Real Prediksi	$ A_i - F_i $	$ A_i - F_i ^2$
1	248	248,496	-0,469	0,246
2	248	248,496	-0,469	0,246
3	248	248,496	-0,469	0,246
4	405	404,727	0,273	0,074
5	406	404,727	1,273	1,620
6	406	405,564	0,436	0,190
MSE				0,437

Pada tabel 4.7 ditampilkan nilai hasil proses prediksi sample dari nilai *real* dan nilai *real* prediksi diambil sebanyak enam data dengan tiga data awal dan tiga data akhir sebelum menjadi nilai *future value* agar bisa dilihat akurasi dari model dengan menggunakan *Mean Absolute Error* dan *Mean Square Error*. Dari hasil grafik pada gambar 4.3 yang didapatkan *output* nilai yang dikeluarkan adalah nilai *future value*. Dari nilai *future value* yang dikeluarkan pada metode *Optimally Pruned Extreme Learning Machine* sebanyak dua bulan sampai tiga bulan dari ketika user menjalankan proses prediksi, ketika user menjalankan prediksi pada bulan agustus maka user mendapatkan *output* bulan Agustus, September, dan Oktober. *Output* dari nilai *future value* seperti pada gambar 4.4. Kemudian data perjam di cari nilai tertinggi untuk menjadi perhari seperti pada gambar 4.5 dan berlaku untuk perbulan juga dicari nilai *delta* atau selisih untuk mencari data perbulan seperti pada gambar 4.6 dan gambar 4.7.

406.2001	7/31/2021 0:24
406.2001	7/31/2021 1:24
406.2001	7/31/2021 2:24
406.2001	7/31/2021 3:24
406.2001	7/31/2021 4:24

Gambar 4.4 Data Perjam

date	kwh
7/30/2021	406.2001
7/31/2021	406.2001
8/1/2021	423.4297
8/2/2021	439.3265
8/3/2021	442.0822

Gambar 4.5 Data Perhari

date	kwh	-1h	dt
7/30/2021	406.2001	0	406.2001
7/31/2021	406.2001	406.2001	0
8/1/2021	423.4297	406.2001	17.2296
8/2/2021	439.3265	423.4297	15.89678
8/3/2021	442.0822	439.3265	2.75572

Gambar 4.6 Selisih Antar Hari

date	sum	tarif
7/31/2021	406.2001	298557.1
8/31/2021	283.8706	208644.9
9/30/2021	22.12016	16258.32
10/31/2021	3.3146	2436.231

Gambar 4.7 Jumlah Tarif Perbulan

5. Kesimpulan dan Saran

5.1 Kesimpulan

Berdasarkan pengujian model terbaik dari algoritma *Optimally Pruned Extreme Learning Machine* didapat MAE sebesar 0,14935 dan MSE sebesar 0,08034 pada parameter data *train* dan *test*, *neuron hidden* sebesar 250, parameter *alpha* sebesar 0,8, parameter *rbf width* sebesar 1,0, parameter *ridge alpha* sebesar 0,002, dan fungsi aktivasi Sigmoid.

5.2 Saran

Berdasarkan dari hasil pengujian yang telah dilakukan pada tugas akhir, maka hal yang dapat penulis sarankan pada penelitian selanjutnya adalah sebagai berikut

1. Dalam pembacaan data masih dibutuhkan waktu yang sangat lama, mungkin karena pemrosesan pada data *input* masih belum optimal sehingga perlu di tinjau lagi
2. Perlu diberikan beberapa parameter *input* tambahan agar dapat menghasilkan tingkat akurasi yang lebih baik lagi.

:

Referensi

- [1] Darma, S., Yusmartanto., dan Akhiruddin (2019), "Studi sistem penerapan kwh meter", 4(3), 158–165.
- [2] Mahusin, N. A., dan Baharun, R. (2014), "Utility consumption among Malaysian electricity users in government buildings", *ISTMET 2014 - 1st International Symposium on Technology Management and Emerging Technologies, Proceedings*, (January), 383–387.
- [3] Santoro, L., Karnoto., dan Yuningtyastuti (2014), "Analisis Pola Beban Listrik Wilayah Jawa Tengah Dan Diy Menggunakan Strategi Demand Side Management (Dsm)", *Transmisi*, 16(3), 135–142.
- [4] McNeil, M. A., Karali, N., dan Letschert, V. (2019), "Forecasting Indonesia's electricity load through 2030 and peak demand reductions from appliance and lighting efficiency", *Energy for Sustainable Development*, 49, 65–77.
- [5] Wijaya, A. H. (2019), "Artificial Neural Network Untuk Memprediksi Beban Listrik Dengan Menggunakan Metode Backpropagation", *Jurnal CoreIT*, 5(2), 61–70.
- [6] Miche, Y., Sorjamaa, A., Bas, P., Simula, O., Jutten, C., dan Lendasse, A. (2010), "Brief Papers OP-ELM: Optimally Pruned Extreme Learning Machine", 21(1), 158–162.
- [7] Jayanti, H. D., Cholissodin, I., dan 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), 4895–4904.
- [8] Perdana, J. A., Soeprijanto, A., dan Wibowo, S. (2012), "Peramalan Beban Listrik Jangka Pendek Menggunakan Optimally Pruned Extreme Learning Machine (OPELM) pada Sistem Kelistrikan Jawa Timur", *Jurnal Teknik ITS*, 1(1), 64–69.
- [9] Sorjamaa, A., Miche, Y., Weiss, R., dan Lendasse, A. (2008), "Long-term prediction of time series using NNE-based projection and OP-ELM", *Proceedings of the International Joint Conference on Neural Networks*, 2674–2680.
- [10] Wang, Z., & Parth, Y. (2016). *Extreme Learning Machine for Multi-class Sentiment Classification of Tweets. August 2017*, 1–11.
- [11] Feng, J., dan Lu, S. (2019), "Performance Analysis of Various Activation Functions in Artificial Neural Networks", *Journal of Physics: Conference Series*, 1237.
- [12] Nwankpa, C. E., Ijomah, W., Gachagan, A., dan Marshall, S. (2018), "Activation functions: Comparison of trends in practice and research for deep learning", *ArXiv*, 1–20
- [13] Karlik, B., dan Olgac, V. A. (2011), "Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks", *International Journal of Artificial Intelligence And Expert Systems (IJAE)*, 111–122.
- [14] Sovilj, D., Sorjamaa, A., Yu, Q., Miche, Y., & Séverin, E. (2010), "OPELM and OPKNN in long-term prediction of time series using projected input data", *Neurocomputing*, 73(10–12), 1976–1986.
- [15] Laman resmi PLN .Online <https://web.pln.co.id/pelanggan/tarif-tenaga-listrik>, diakses pada 30 Juli 2021.