

PREDIKSI PENGGUNAAN ENERGI LISTRIK MENGUNAKAN METODE FEEDFORWARD NEURAL NETWORK

PREDICTION OF ELECTRICITY USING FEEDFORWARD NEURAL NETWORK METHOD

Alifti Hammains¹, Casie Setianingsih², Muhammad Ary Murti³

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

aliftihammains@student.telkomuniversity.ac.id¹, setiacasie@telkomuniversity.ac.id²,
arymurti@telkomuniversity.ac.id³

Abstrak

Memprediksi total biaya penggunaan energi listrik dengan tingkat akurasi yang tinggi sangatlah penting. Penerapan metode yang sesuai sangat berpengaruh terhadap tingkat akurasi yang dihasilkan dalam prediksi. Dalam prediksi ini menggunakan metode *Feedforward Neural Network* (FFNN) dengan algoritma *Backpropagation*. Dalam Tugas Akhir ini akan membuat sistem berbasis web untuk melakukan prediksi penggunaan energi listrik dengan model *neural network*. *feed forward neural network* (FFNN) merupakan model yang lebih sering digunakan karena dikenal memiliki kemampuan pendekatan yang baik dan bersifat universal. Selain itu, metode FFNN telah dikenal akan keunggulannya, yaitu memiliki nilai prediksi yang sangat mendekati nilai aktualnya sehingga menghasilkan *error* yang kecil serta memiliki kemampuan untuk mendeteksi atau melakukan analisis untuk permasalahan yang bersifat sangat kompleks. Untuk itu penelitian ini menggunakan metode *Feedforward Neural Network* dalam memprediksi total biaya penggunaan energi listrik dengan dipengaruhi oleh jumlah unit *neuron* pada *hidden layer*, yang memungkinkan nilai *error* yang di dapat lebih kecil. Keakuratannya pada metode ini bisa di lihat dengan menggunakan MSE (*Mean Square Error*). Pada Tugas Akhir ini menggunakan data *history* penggunaan kWh Gedung P Fakultas Teknik Elektro. Hasil pengujian FFNN menggunakan parameter terbaik yaitu dengan partisi data 70% data *training* 30% data *testing*, *learning rate* 0.001, dan *epoch* sebesar 80 sehingga menghasilkan nilai MSE sebesar 0.35037.

Kata Kunci: Prediksi, *Feedforward Neural Network* (FFNN), *error*.

Abstract

Predicting the total cost of using electrical energy with a high degree of accuracy is very important. The application of the appropriate method greatly affects the level of accuracy produced in the prediction. This prediction uses Feedforward Neural Network (FFNN) method with Backpropagation algorithm. In this final project will create a web-based system to predict the use of electrical energy with a neural network model. feed forward neural network (FFNN) is a model that is more often used because it is known to have good approximation capabilities and universal. In addition, the FFNN method is known for its advantages, namely having a predictive value that is very close to the actual value so that it produces a small error and has the ability to detect or perform analysis for very complex problems. For this reason, this study uses the Feedforward Neural Network method in predicting the total cost of using electrical energy by being influenced by the number of neuron units in the hidden layer, which allows the error value to be smaller. Accuracy In this method can be seen by using the MSE (Mean Square Error). In this Final Task using historical data on the use of kWh Building P Faculty of Electrical Engineering. FFNN test results use the best parameters, namely with a data partition of 70% data training 30% data testing, learning rate 0.001, and epoch of 80 resulting in mse value of 0.35037.

Keywords: Prediction, Feedforward Neural Network (FFNN), error.

1. Pendahuluan

Energi listrik merupakan salah satu yang mempengaruhi kehidupan manusia saat ini, dimana hampir semua aktifitas manusia berhubungan dengan energi listrik. Penggunaan energi listrik dapat dilihat secara langsung baik di lingkungan rumah tangga, sekolah, rumah sakit, perkantoran, dan industri-industri. Dalam penggunaan energi listrik ditetapkan tarif bulanan sesuai dengan pemakaian. Tagihan setiap bulannya tidak selalu sama, dikarenakan pemakaian serta daya yang digunakan pelanggan berbeda. Diperlukan perancangan anggaran biaya tagihan listrik. Dalam hal ini dilakukan penelitian prediksi total biaya energi listrik dengan metode *feedforward neural network*.

Pada *feed forward neural network* selain dari jumlah parameter yang digunakan, data time series dipengaruhi oleh jumlah unit *neuron* pada lapisan tersembunyi, yang memungkinkan nilai *error* semakin kecil dengan algoritma

beckpropagation. Keakuratan hasil prediksi sangat penting untuk membatu penelitian ini dengan menggunakan metode *feedforward neural network*.

2. Landasan Teori

2.1 Listrik

Listrik merupakan suatu muatan yang terdiri dari muatan positif dan muatan negatif, dimana sebuah benda akan dikatakan memiliki energi listrik apabila suatu benda itu mempunyai perbedaan jumlah muatan. Energi listrik banyak di gunakan untuk berbagai peralatan atau mesin. Energi listrik tidak dapat dilihat secara langsung namun dampak atau akibat dari energi listrik dapat dilihat seperti sinar atau cahaya bola lampu[1].

2.2 kiloWatt Hour (kWh)

kWh Meter adalah alat penghitung pemakaian energi listrik. Alat ini bekerja menggunakan metode induksi medan magnet dimana medan magnet tersebut menggerakkan piringan yang terbuat dari aluminium. Pengukur Watt atau Kwatt, yang pada umumnya disebut Watt-meter/Kwatt meter disusun sedemikian rupa, sehingga kumparan tegangan dapat berputar dengan bebasnya, dengan jalan demikian tenaga listrik dapat diukur, baik dalam satuan WH (watt Jam) ataupun dalam kWh (kilowatt Hour)[2].

2.3 Prediksi

Prediksi adalah ilmu pengetahuan untuk memprediksikan sesuatu yang akan terjadi di masa depan. Prediksi dapat dilakukan menggunakan data-data masa lalu yang diolah menggunakan metode prediksi. Tujuan dari prediksi adalah menjadi acuan pengambilan keputusan tentang sesuatu yang terjadi di masa depan yang telah diperkirakan di masa saat ini. Teknik prediksi terbagi menjadi dua, diantaranya adalah[1]:

1. Prediksi Kualitatif

Prediksi yang menggunakan intuisi, pengalaman pribadi, dan berdasarkan pendapat (*judgement*) dari yang melakukan prediksi.

2. Prediksi Kuantitatif

Prediksi yang didasarkan pada informasi tentang masa lalu dengan asumsi bahwa beberapa aspek pola masa lalu akan terus berjalan pada masa yang akan datang. Data masa lalu dapat dipresentasikan menjadi suatu nilai atau angka yang sering disebut dengan data time series.

2.4 Neural Network

Neural Network merupakan suatu metode *Artificial Intelligence* yang konsepnya meniru sistem jaringan syaraf yang ada pada tubuh manusia, dimana dibangun node-node yang saling berhubungan satu dengan yang lainnya. Node-node yang terhubung melalui suatu *link* yang bisa disebut dengan istilah *weight*. Metode untuk menentukan nilai *weight* disebut dengan *training*, *learning*, atau algoritma. Setiap *neuron* menggunakan fungsi aktivasi pada *input* untuk menentukan prediksi *output*[3].

Neuron-neuron dalam *neural network* di susun berkelompok, yang disebut dengan *layer* (lapis). Susunan neuron-neuron dalam lapisan dan pola koneksi di dalam dan antara lapisan disebut dengan arsitektur jaringan. Arsitektur ini merupakan salah satu karakteristik penting yang membedakan *neural network*.

Secara umum ada tiga lapisan yang membentuk neural network, yaitu[3]:

1. Lapisan Input

Unit-unit di lapisan input disebut unit-unit input. Unit-unit input tersebut menerima pola inputan dari luar yang menggambarkan suatu permasalahan. Banyak node atau neuron dalam lapisan input tergantung pada banyaknya input dalam model dan setiap input menentukan satu neuron .

2. Lapisan Tersembunyi (hidden layer)

Unit-unit dalam lapisan tersembunyi disebut unit-unit tersembunyi, di mana outputnya tidak dapat diamati secara langsung. Lapisan tersembunyi terletak di antara lapisan input dan lapisan output, yang dapat terdiri atas beberapa lapis tersembunyi.

3. Lapisan Output

Unit-unit dalam lapisan output disebut unit-unit output. Output dari lapisan ini merupakan solusi neural network terhadap suatu permasalahan. Setelah melalui proses training, network merespon input baru untuk menghasilkan output yang merupakan hasil prediksi .

2.5 Feedforward Neural Network

Feedforward Neural Network atau disingkat FFNN, merupakan salah satu arsitektur neural network yang outputnya tidak mempengaruhi input setelahnya. Input layer atau lapisan input merupakan lapisan parameter-parameter untuk masuk kedalam proses secara paralel. Dalam hidden layer atau lapisan tersembunyi input akan diolah dengan fungsi linear ataupun *sigmoid*. Setelah semua node pada lapisan tersembunyi selesai diolah, maka akan dikeluarkan pada layer output atau lapisan output [5]. Langkah-langkah algoritma pelatihan *feedforward neural network*:

Perhitungan Maju (Feedforward)

1. Setiap unit input yang terdiri dari ($X_i, i = 1, 2, 3, \dots, n$) akan menerima sinyal dari *input* X_i dan melanjutkannya ke *hidden layer* di atasnya [12].
2. Pada setiap unit di *hidden layer* yaitu, ($Z_{i,j} = 1, 2, 3, \dots, p$) menambahkan bobot sinyal – sinyal pada masukan

$$z_{net\ j} = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (2.1)$$

Fungsi aktivasi diterapkan dalam menghitung sinyal output:

$$z_j = \frac{1}{1+e^{-z_{net\ j}}} \quad (2.2)$$

3. Untuk unit pada *output* ($Y_{k, k} = 1, 2, 3, \dots, m$) menghitung bobot pada sinyal-sinyal *output*

$$y_{net\ k} = w_{ok} \sum_{j=1}^p z_j w_{jk} \quad (2.3)$$

Fungsi aktivasi yang diterapkan dalam menghitung sinyal-sinyal *output* adalah:

$$z_j = \frac{1}{1+e^{-z_{net\ j}}} \quad (2.4)$$

Perhitungan Mundur (*Backpropagation*)

1. Menghitung δ sebagai faktor unit output berdasarkan error di setiap unit *output*

$$\delta_k = (t_k - y_k) f'(y_{net\ k}) \quad (2.5)$$

Kemudian menghitung perubahan dari nilai bobot untuk mengganti nilai w_{jk} dengan menggunakan α sebagai percepatan:

$$\Delta w_{kj} = \alpha \delta_k z_j \quad (2.6)$$

2. Untuk setiap unit pada *hidden layer* yaitu, ($Z_{i,j} = 1, 2, 3, \dots, p$) menjumlahkan delta inputnya berdasarkan error

$$\delta_{net\ j} = \sum_{k=1}^m \delta_k w_{jk} \quad (2.7)$$

3. Selanjutnya, kalikan nilai yang sudah di dapat dengan menggunakan fungsi aktivasi pada turunannya yang dipakai untuk perhitunagn kesalahan pada *hidden layer*:

$$\delta_j = \delta_{net\ j} f'(z_{net\ j}) = \delta_{net\ j} z_j (1 - z_j) \quad (2.8)$$

4. Nilai bobot dari v_{ji} dihitung untuk mengetahui perubahan nilai bobotnya:

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (2.9)$$

5. Memperbaharui nilai bobot

$$w_{kj} (\text{baru}) = w_{kj} (\text{lama}) + \Delta w_{kj} \quad (2.10)$$

2.5.1 Backpropagation

Backpropagation merupakan salah satu algoritma pembelajaran yang paling umum digunakan dalam jaringan syaraf tiruan. Metode ini melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan dalam mengenali pola selama proses pelatihan serta memberikan respon yang benar terhadap pola masukan yang serupa namun tidak sama dengan pola yang dipakai selama pelatihan[6].

Backpropagation bekerja melalui proses iteratif dengan menggunakan sekumpulan data latih lalu membandingkan nilai prediksi dari jaringan yang telah dibangun dengan nilai sesungguhnya. Backpropagation melakukan proses pembelajaran dengan menggunakan pola penyesuaian bobot dari arsitektur jaringan

2.5.2 Learning Rate

Learning rate adalah tingkat pembelajaran suatu sistem cerdas, maksudnya adalah tingkat adaptasi sistem terhadap perubahan yang terjadi jika target yang ditentukan tidak tercapai. Rentang learning rate yang digunakan antara 0.0-1.0. Penggunaan learning rate adalah pada tahap feedbackward propagation di mana perubahan nilai weight dan bias yang ada dalam sistem akan dipengaruhi juga oleh nilai learning rate ini.

2.5.3 Epoch

Epoch adalah ketika seluruh dataset sudah melalui proses training pada Neural Network sampai dikembalikan ke awal untuk sekali putaran, karena satu Epoch terlalu besar untuk dimasukkan (feeding) kedalam komputer maka dari itu kita perlu membaginya kedalam satuan kecil (batches).

2.6 Fungsi Aktivasi

Fungsi aktivasi merupakan penentu diteruskan atau tidaknya sinyal dari *input neuron*. Dalam *backpropagation*, fungsi aktivasi yang digunakan harus memenuhi beberapa syarat, yaitu *kontinu*, *terdiferensial* dengan mudah dan fungsi tersebut merupakan fungsi tidak turun. Terdapat beberapa fungsi aktivasi yang sering digunakan dalam jaringan syaraf tiruan, diantaranya fungsi *ReLU* [8].

ReLU (Rectified Linier Unit) merupakan fungsi aktivasi pada Artificial Neural Network yang saat ini banyak digunakan, berikut rumus pada ReLU:

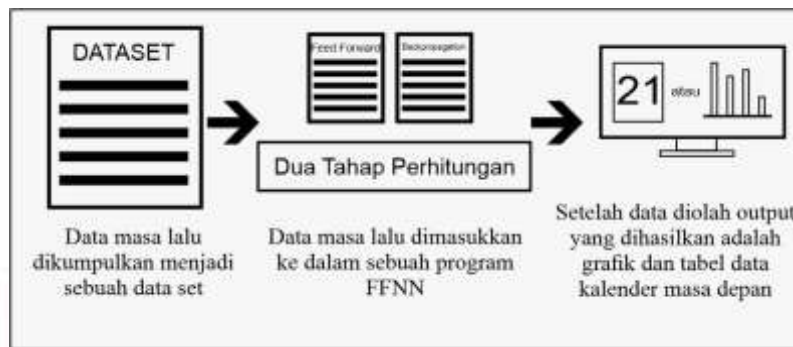
$$f(x) = \max(x, 0) \tag{2.11}$$

Jika x kurang dari 0 maka hasil $f(x)$ adalah 0 dan ketika x bernilai 0 atau lebih dari 0 maka hasil dari $f(x)$ adalah x itu sendiri.

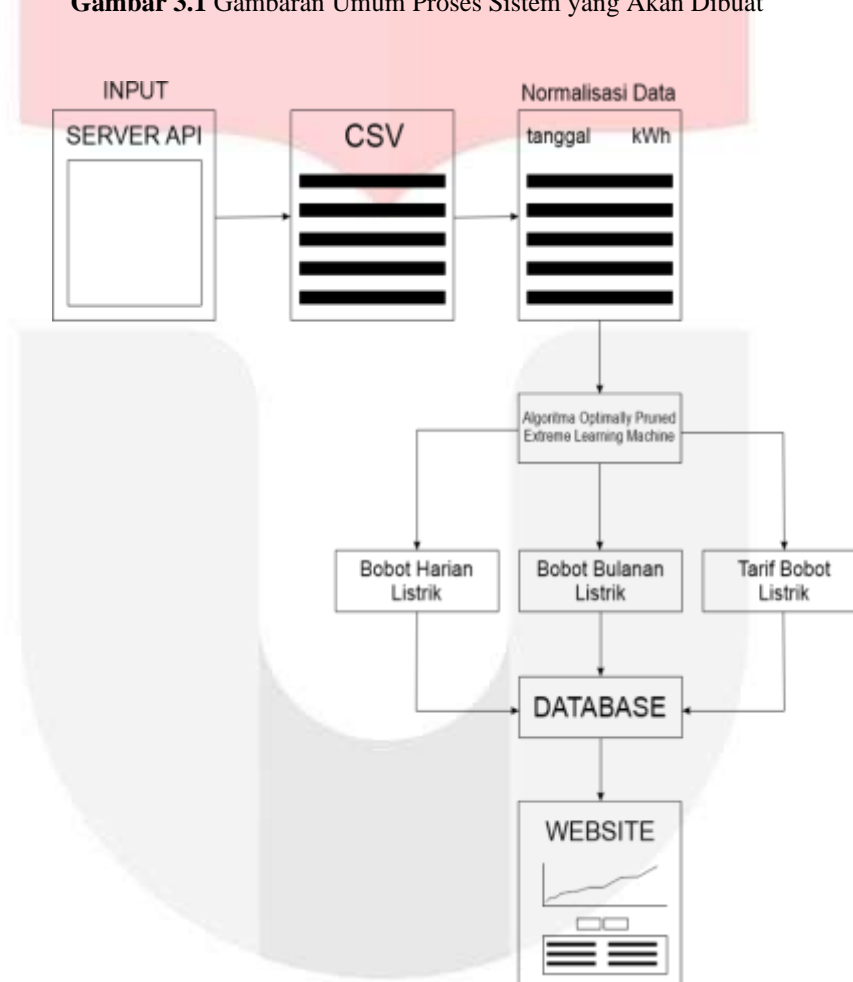
3. Perancangan

3.1 Gambaran Umum Sistem

Dalam perancangan model yang dibuat secara umum sistem yang akan dibuat seperti gambar dibawah:



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 *Feedforward Neural Network*, 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 Arsitektur Feedforward Neural Network

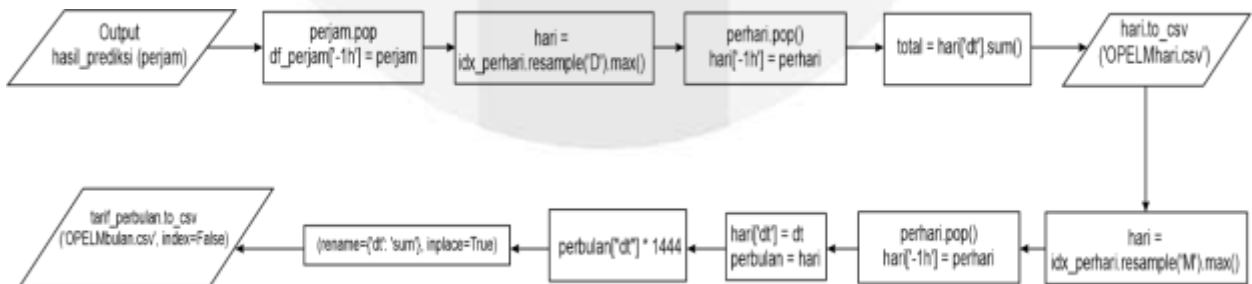
Feedforward Neural Network merupakan sebuah jaringan multi layer yang mempunyai lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan output (*output layer*).



Gambar 3.4 Arsitektur Jaringan Feedforward Neural Network

3.2.3 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.

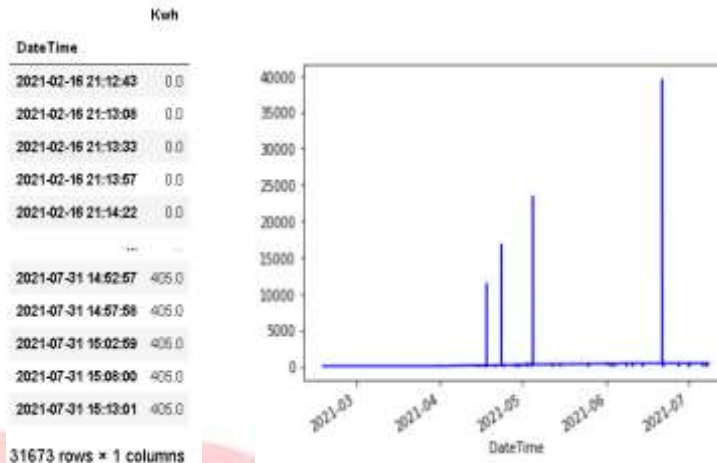


Gambar 3.6 Diagram Alir Output

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 Partisi Data

Dalam pengujian ini dilakukan sebanyak lima kali dan dilakukan pada partisi data yang telah didapat menjadi data uji dan data latih yang berbeda-beda.

Tabel 4.1 Hasil Pengujian Partisi Data

NO	Pengujian	Partisi Data		Learning Rate	Epoch	MSE
		Train	Test			
1.	Pertama	50%	50%	0.001	80	0.61996
2.	Kedua	60%	40%			0.46993
3.	Ketiga	70%	30%			0.36910
4.	Keempat	80%	20%			0.37345
5.	Kelima	90%	10%			0.63060

Dapat dilihat bahwa pengujian ketiga memperoleh nilai MSE terkecil yaitu 0.36910 pada data train dimana nantinya partisi tersebut akan dipakai untuk pengujian selanjutnya. Untuk pengujian ini menggunakan learning rate 0.001 dan epoch 80.

4.3 Pengujian Learning Rate

Dalam pengujian ini menggunakan nilai epoch sebesar 80 dengan partisi data dengan selisih MSE terkecil yaitu 70% data training dan 30% data testing.

Tabel 4.2 Hasil Pengujian Learning Rate

NO	Pengujian	Learning Rate	Epoch	MSE
1.	Pertama	0.001	80	0.36208
2.	Kedua	0.002		0.39116
3.	Ketiga	0.003		0.52417
4.	Keempat	0.004		0.39096
5.	Kelima	0.005		0.44614

Nilai learning rate terbaik berada pada pengujian pertama sebesar 0.001 menghasilkan nilai MSE terkecil, yaitu 0.36208 pada data train.

4.4 Pengujian Epoch

Dalam pengujian ini dapat dilihat bahwa pengujian epoch yang dilakukan sebanyak lima kali percobaan dengan nilai epoch yang berbeda-beda menggunakan nilai partisi data 70% data training dan 30% data testing, nilai learning rate 0.001.


Tabel 4.3 Hasil Pengujian Epoch

NO	Pengujian	Epoch	Learning Rate	MSE
1.	Pertama	20	0.001	0.40046
2.	Kedua	40		0.36566
3.	Ketiga	60		0.53073
4.	Keempat	80		0.35037
5.	Kelima	100		0.36700


Berdasarkan tabel 4.3 epoch yang menghasilkan nilai MSE terkecil yaitu nilai epoch 80 dengan MSE 0.35037 pada data train.

4.4.1 Hasil Output

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 4.4 Tabel Hasil Data Test MSE

No	Nilai Real	Nilai Prediksi	$ A_i - F_i $	$ A_i - F_i ^2$
1	285	283.741	1.259	0.6079
2	286	285.7529	0.2471	3.1673
3	287	286.7589	0.2411	3.1837
4	287	287.7651	0.7651	0.0424
5	287	287.7651	0.7651	0.0424
			MSE	1.4087

Pada tabel 4.4 ditampilkan nilai hasil proses prediksi sample diambil sebanyak lima data dengan tiga data awal sebelum menjadi nilai future value agar penulis bisa melihat akurasi dari model dengan menggunakan Mean Square Error.

Dari hasil grafik pada gambar 4.2 yang didapatkan output nilai yang dikeluarkan adalah nilai future value. nilai future value yang dikeluarkan pada metode Feedforward Neural Network 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 dan nilai real seperti pada gambar 4.3. Penulis mengambil nilai real terakhir karena penulis menggunakan input kWh yang dipastikan bentuknya naik jadi penulis mengambil nilai real terakhir dan nilai prediksi awal agar bentuk data terus naik.

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
406.2001	7/31/2021 5:24
406.2001	7/31/2021 6:24
406.2001	7/31/2021 7:24
406.2001	7/31/2021 8:24
406.2001	7/31/2021 9:24
406.2001	7/31/2021 10:24
406.2001	7/31/2021 11:24
406.2001	7/31/2021 12:24
406.2001	7/31/2021 13:24
406.2001	7/31/2021 14:24
406.2001	7/31/2021 15:24
406.2001	7/31/2021 16:24
406.2001	7/31/2021 17:24
406.2001	7/31/2021 18:24
406.2001	7/31/2021 19:24
406.2001	7/31/2021 20:24
406.2001	7/31/2021 21:24
406.2001	7/31/2021 22:24
406.2001	7/31/2021 23:24
406.2001	8/1/2021 0:24
406.2001	8/1/2021 1:24
406.2001	8/1/2021 2:24

Gambar 4.4 Data Perjam

7/29/2021 13:00	405
7/29/2021 14:00	405
7/29/2021 15:00	405
7/29/2021 16:00	405
7/29/2021 17:00	405
7/29/2021 18:00	405
7/29/2021 19:00	405
7/29/2021 20:00	405
7/29/2021 21:00	405
7/29/2021 22:00	405
7/29/2021 23:00	405
7/30/2021 0:00	405
7/30/2021 1:00	405
7/30/2021 2:00	405
7/30/2021 3:00	405
7/30/2021 4:00	405
7/30/2021 5:00	405
7/30/2021 6:00	405
7/30/2021 7:00	405
7/30/2021 8:00	405
7/30/2021 9:00	405
7/30/2021 10:00	405
7/30/2021 11:00	405
7/30/2021 12:00	405
7/30/2021 13:00	405
7/30/2021 14:00	405
7/30/2021 15:00	405
7/30/2021 16:00	405
7/30/2021 17:00	405
7/30/2021 18:00	405
7/30/2021 19:00	405

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
8/4/2021	442.0822	442.0822	0
8/5/2021	442.0822	442.0822	0
8/6/2021	442.0822	442.0822	0
8/7/2021	442.0822	442.0822	0
8/8/2021	452.5269	442.0822	10.44466
8/9/2021	458.3355	452.5269	5.80859
8/10/2021	472.4536	458.3355	14.1181
8/11/2021	484.5122	472.4536	12.0586
8/12/2021	501.0403	484.5122	16.52819
8/13/2021	504.1195	501.0403	3.07916
8/14/2021	504.1195	504.1195	0
8/15/2021	520.5974	504.1195	16.47785
8/16/2021	545.5536	520.5974	24.95625
8/17/2021	548.2275	545.5536	2.6739
8/18/2021	572.7344	548.2275	24.50694
8/19/2021	584.6495	572.7344	11.91506
8/20/2021	588.1013	584.6495	3.4518
8/21/2021	590.2937	588.1013	2.1924
8/22/2021	602.3577	590.2937	12.064
8/23/2021	604.2132	602.3577	1.8555
8/24/2021	622.3663	604.2132	18.1531
8/25/2021	632.4299	622.3663	10.0636
8/26/2021	653.2957	632.4299	20.86575
8/27/2021	660.2023	653.2957	6.90668
8/28/2021	660.2023	660.2023	0

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

Setelah dilakukan penelitian dan implementasi dapat diberi kesimpulan adalah sebagai berikut:

1. Website sistem prediksi total biaya penggunaan energi listrik berbasis web sudah berjalan dengan baik dengan hasil uji sistem website fungsionalitas dan penggunaan fungsi website sudah dapat berjalan secara normal. Website sistem yang dibuat berhasil melakukan prediksi dalam jangka waktu tiga bulan kedepan untuk melihat hasil prediksi penggunaan energi listrik perhari, perbulan, dan biaya yang dikeluarkan dalam penggunaan listrik perbulan.
2. Pada pengujian model terbaik dari algoritma Feedforward Neural Network didapat nilai MSE sebesar 0.35037 menggunakan paramater terbaik adalah partisi data sebesar 70% data training dan 30% data testing, learning rate 0.001, dan nilai epoch 80.

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] Markidakis , "Metode dan Aplikasi Peramalan," Erlangga Jakarta, 1995.
- [2] Z. Zhong, "Time Series Forecasting Using a Hybrid RBF Neural Network and AR Model Based on Binomial Smoothing," Word Academy of Science, Enggining and Technology 75, 2011.
- [3] Kriesel D, "A Brief Introduction to Neural Network," 2007.
- [4] Robert E. Uhrig, "Introduction to Artifical Neural Network," Prossedings of IECOM Annual Conference on IEEE Industrial Electronics, 1995.
- [5] A. K. H. and Y. Sures, "Multilayer Feedforward Neural Network to Predict the Speed of Wind," IEEE, Bengaluru, 2016.
- [6] S. P. Siregar and A. Wanto, "Analysis of Artificial Neural Network Accuracy Using Backpropagation Algorithm In Predicting Process Forecasting," Int. J. Inf. Syst. Technol., vol. 1, no. 1, pp. 34–42, 2017.
- [7] P. Antwi et al., "Estimation of Biogas and Methane Yields in an UASB Treating Potato Starch Processing Wastewater With Backpropagation Artificial Neural Network," Journal Bioresour Technology, vol. 228, pp. 106–115, 2017.
- [8] D. Huang and Z. Wu, "Forecasting Outpatient Visits Using Empirical Mode Decomposition Coupled With Backpropagation Artificial Neural Networks Optimized by Particle Swarm Optimization," PLoS One, vol. 12, no. 2, pp. 1–18, 2017.
- [9] Fausett, Laurene, "Fundamentals of Neural Network Architectures, Algorithms, and Application," London : Prentice Hall, Inc, 1994.
- [10] Chang, P.-C., Wang, Y.-W. & Liu, C.-H., " The Development of a Weighted Evolving Fuzzy Neural Network for PCB Sales Forecasting," Expert Systems with Applications, Volume 32, pp. 88 – 89, 2007.
- [11] Mohammadi, K. et al., " Predicting The Wind Power Density Based Upon Extreme Learning Machine," Energy, Volume 86, pp. 232-239, 2015.
- [12] M. F. Almas, B. D. Setiawan, Sutrisno, " Implementasi Metode Beckpropagation untuk Prediksi Harga Batu Bara," Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, 2018.
- [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] Novita, D., & Amelia, L. (2019). Analisis Usability Aplikasi Pengisian Krs Online Stmik Xyz Palembang Menggunakan Use Questionnaire. *Jurnal Informasi Dan Komputer*, 7(1), 17–28.

