

Received :

Accepted :

Published :

## PREDIKSI PENGGUAAAN BEBAN LISTRIK SISTEM MAHAKAM MENGGUNAKAN JARINGAN SYARAF TIRUAN DENGAN MENGGUNAKAN ALGORITMA BACKPROPAGATION

Rizky Yolanda<sup>1\*</sup>, M. Ihsan Alfani Putera<sup>2</sup>, Dwi Arief Prambudi<sup>3</sup>

<sup>1,2,3</sup>Institut Teknologi Kalimantan

\*10161081@student.itk.ac.id

### Abstract

Along with the increasing population in East Kalimantan, economic activities, community social activities and the increasing use of electrical equipment have caused the demand for electricity to become uncertain. To meet these needs, PLN UP3B needs to predict the use of electricity loads. Prediction of the use of electrical loads needs to be done to determine future electricity needs to get a balance so that electricity needs are met appropriately. One method that can be used to predict is an Artificial Neural Network (ANN) using the Backpropagation algorithm. Therefore, in this study ANN was used to predict the use of electrical loads in the Mahakam System of East Kalimantan. The data used in this study is data on the use of electricity in the Mahakam System for the last six years with daily intervals, from January 2015 to December 2020 and uses data with a composition of 60% training data and 40% test data. This research was conducted using 11 test models, where the architecture contains 24 nodes in the input layer, 2-12 nodes in the hidden layer and 24 nodes in the output layer to determine the best prediction model. After doing research, it was found that model 1 using 2 nodes in the hidden layer as the best model with MSE of 0.002616 on training data and 0.004242 on testing data. The results of the study are in the form of the best prediction model for forecasting daily electrical loads and examples of prediction results from using the model. Thus, these results will be used as recommendations for PLN UP3B as an alternative electricity load prediction model for the next seven days.

Keywords : Algoritma Backpropagation, Artificial Neural Networks, Electric Load

### Abstrak

Seiring dengan meningkatnya jumlah penduduk di Kalimantan Timur, aktivitas kegiatan ekonomi, kegiatan sosial masyarakat serta meningkatnya konsumsi penggunaan peralatan listrik menyebabkan permintaan listrik yang tidak menentu. Untuk memenuhi kebutuhan tersebut, PLN UP3B perlu melakukan prediksi penggunaan beban listrik. Prediksi penggunaan beban listrik perlu dilakukan untuk mengetahui kebutuhan listrik pada masa depan untuk memperoleh keseimbangan agar kebutuhan tenaga listrik terpenuhi secara tepat. Salah satu metode yang dapat digunakan untuk memprediksi adalah Jaringan Syaraf Tiruan (JST) dengan menggunakan algoritma Backpropagation. Oleh karena itu pada penelitian ini digunakan JST untuk memprediksi penggunaan beban listrik pada Sistem Mahakam Kalimantan Timur. Data yang digunakan pada penelitian ini ialah data penggunaan beban listrik Sistem Mahakam selama enam tahun terakhir dengan interval perhari, yang terhitung dari Januari 2015 sampai dengan Desember 2020 dan menggunakan data dengan komposisi 60% data training dan 40% data testing. Penelitian dilakukan dengan menggunakan 11 model uji, dimana arsitektur berisikan 24 node pada input layer, 2-12 node pada hidden layer dan 24 node pada output layer untuk menentukan model prediksi terbaik. Setelah melakukan penelitian didapatkanlah model 1 menggunakan 2 node pada hidden layer sebagai model terbaik dengan MSE sebesar 0.002616 pada data training dan 0.004242 pada data testing. Hasil penelitian berupa model prediksi terbaik untuk peramalan beban listrik harian dan contoh hasil prediksi dari penggunaan model tersebut. Dengan demikian, hasil tersebut akan dijadikan rekomendasi bagi PLN UP3B sebagai model prediksi beban listrik alternatif untuk tujuh hari ke depan.

*Kata kunci : Algoritma Backpropagation, Beban Listrik, Jaringan Syaraf Tiruan*

## 1. Pendahuluan

Penggunaan listrik di Indonesia selalu mengalami peningkatan setiap tahunnya. Peningkatan penggunaan listrik setiap tahunnya haruslah diimbangi dengan penyediaan bahan bakar serta tenaga listrik yang memadai. Maka dari itu, Indonesia haruslah siap dengan permasalahan yang akan terjadi kedepannya terkait penyediaan tenaga listrik.

Kalimantan Timur merupakan salah satu daerah yang sering mengalami pemadaman listrik [1]. Salah satu alasan yang membuat seringnya terjadi pemadaman listrik adalah pasokan sumber daya yang kurang mengakibatkan cadangan listrik menjadi dibawah standar. Maka dari itu, Kalimantan Timur menyediakan sebuah sistem kelistrikan yang dapat memberikan ketersediaan energi listrik yang cukup dan mencegah terjadinya pemadaman listrik yang disebut dengan Sistem Mahakam.

Sistem Mahakam merupakan sistem pembangkit dan sistem distribusi di Kalimantan Timur. Sistem ini menghubungkan pembangkit-pembangkit yang ada di Balikpapan, Kutai Kartanegara, Samarinda dan Bontang [2]. Daya mampu Sistem Mahakam mencapai 547,63 MW dengan beban puncak sebesar 392, 17 MW, sehingga sistem ini memiliki 155,46 MW daya cadangan [3]. Banyaknya pembangkit listrik menyebabkan cukupnya ketersediaan energi listrik untuk saat ini. Akan tetapi, seiring dengan meningkatnya jumlah penduduk setiap tahunnya menyebabkan meningkatnya permintaan listrik dari waktu ke waktu. Aktivitas atau kegiatan ekonomi pengguna, kegiatan sosial masyarakat serta meningkatnya konsumsi penggunaan peralatan listrik juga dapat menyebabkan meningkatnya permintaan listrik [4]. Dalam penyediaan energi listrik, apabila energi listrik yang dihasilkan memiliki kelebihan daya menyebabkan *overload* tempat penyimpanan dan apabila energi tidak digunakan maka energi listrik yang dihasilkan tidak dapat disimpan. Disisi lain, Jika energi listrik yang dibutuhkan

lebih besar dari energi yang dibangkitkan pembangkit listrik maka dapat menyebabkan underload tempat penyimpanan dan menyebabkan pemadaman secara bergilir. Penggunaan listrik yang tidak menentu ini mengharuskan perusahaan penyedia listrik Kalimantan Timur perlu melakukan prediksi penggunaan beban listrik. Prediksi dilakukan agar kebutuhan tenaga listrik dapat terpenuhi secara tepat dan tidak ada bahan bakar ataupun energi yang terbuang [4].

Penelitian ini menerapkan jaringan syaraf tiruan dengan algoritma Backpropagation untuk memprediksi penggunaan beban listrik harian yang ada di Kalimantan Timur. Data yang digunakan adalah data Sistem Mahakam Kalimantan Timur per hari selama enam tahun yang dihitung dari 1 Januari 2015 sampai dengan 31 Desember 2020.

## 2. Metoda Penelitian

### 2.1. Peramalan Beban Listrik

Peramalan merupakan suatu usaha untuk mengetahui keadaan di masa mendatang melalui pengujian keadaan di masa yang lalu. Tujuan dari peramalan adalah perkiraan peristiwa-peristiwa di waktu yang akan datang atas dasar pola-pola keadaan di waktu lalu [5]. Peramalan beban listrik dilakukan untuk memprediksi beban listrik di masa yang akan datang. Ukuran akurasi peramalan yaitu taraf perbedaaan antara hasil peramalan dengan menggunakan permintaan yang sebenarnya terjadi [5].

### 2.2. Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan merupakan sebuah sistem yang meniru cara otak manusia bekerja dalam mengenali pola. Pada Jaringan Syaraf Tiruan dilakukan pemrosesan dari suatu informasi yang terinspirasi oleh sistem syaraf biologi, sama seperti otak yang mampu memproses sebuah informasi [5]. Jaringan Syaraf Tiruan merupakan salah satu representasi buatan asal otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran di otak manusia. Istilah buatan karena jaringan syaraf ini dibuat dengan mengimplementasikan program

komputer yang mampu menuntaskan sejumlah proses perhitungan selama proses pembelajaran [6].

### 2.3. Algoritma Backpropagation

Algoritma backpropagation merupakan algoritma yang sangat baik dalam menangani masalah pengenalan pola kompleks. Algoritma ini merupakan algoritma jaringan syaraf tiruan yang sering digunakan [6]. Backpropagation merupakan algoritma pembelajaran yang terawasi (supervised learning) dan biasanya digunakan oleh perceptron dengan banyak lapisan (multilayer) untuk mengubah bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyi. Algoritma backpropagation menggunakan error output untuk mengubah nilai bobot-bobotnya dalam arah mundur (backward). Untuk mendapatkan error ini, tahap perambatan maju (forward propagation) harus dikerjakan terlebih dahulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi sigmoid [5].

Pada backpropagation digunakan fungsi aktivasi sebagai fungsi untuk mengaktifkan atau tidak mengaktifkan neuron. Pada algoritma backpropagation karakteristik fungsi aktivasi haruslah kontinu, terdiferensial dan tidak menurun secara terus menerus [7]. Fungsi aktivasi sigmoid biner digunakan dalam melakukan transformasi data, dimana data diubah ke dalam range [0, 1]. Fungsi aktivasi sigmoid biner merupakan fungsi asimtotik (tidak pernah mencapai 0 ataupun 1) maka transformasi data dilakukan ke dalam interval yang lebih kecil yaitu [0.1, 0.8] dapat ditunjukkan ke dalam persamaan (2.12) sebagai berikut [8].

$$X' = \frac{0.8(x - a)}{b - a} + 0.1$$

Dimana:

0.8 = Ketetapan

x = nilai data ke-n

a = data minimum

b = data maksimum

### 2.4. Evaluasi Performa Model Prediksi

Dalam mengevaluasi kinerja model Jaringan Syaraf Tiruan digunakan struktur arsitektur atau pola terbaik dilakukan dengan metode trial dan error atau metode coba-coba sebagai faktor penentu arsitektur JST yang dilakukan dengan melihat error terkecil dari semua model yang ada. Sehingga perhitungan error menjadi suatu pengukuran untuk melihat pola terbaik dari setiap pola yang diuji [9].

Perhitungan error dapat dilakukan dengan *Mean Square Error* (MSE). MSE adalah salah satu metode untuk mengevaluasi metode peramalan. Masing-masing kesalahan atau sisa dikuadratkan. Pendekatan ini mengatur kesalahan peramalan yang besar karena kesalahan-kesalahan itu dikuadratkan [7]. Rumus untuk menghitung MSE dituangkan ke dalam persamaan (2.13) sebagai berikut:

$$MSE = \frac{1}{Q} \sum_{k=1}^Q e_k^2 = \frac{1}{Q} \sum_{k=1}^Q (t_k - a_k)^2$$

Q = Jumlah pola yang dihitung  
 $t_k$  = vector target  
 $a_k$  = vector keluaran jaringan  
 $e_k$  =  $(t_k - a_k)$

## 3. Hasil Penelitian

### 3.1. Perancangan Model Jaringan Syaraf Tiruan

Terdapat beberapa tahap dalam perancangan model jaringan syaraf tiruan antara lain yaitu:

#### 1. *Preprocessing* data

Setelah dilakukan analisa variable pada data, selanjutnya dilakukan data preprocessing. Pada data preprocessing dibagi menjadi tahapan data cleaning dan normalisasi data. Adapun tahapannya adalah sebagai berikut.

##### a. *Data Cleaning*

Pada penelitian dilakukan analisa variable, ditemukan data yang terdapat nilai kosong dan data yang tidak konsisten. Pada penelitian ini dilakukan penghapusan terhadap *record* yang terdapat nilai kosong dan data yang tidak konsisten. Proses ini dilakukan dengan cara

menghapus *record* data menggunakan Microsoft Excel.

#### b. Normalisasi Data

Pada tahap normalisasi data dilakukan transformasi data kedalam fungsi aktivasi sigmoid biner. Fungsi aktivasi digunakan untuk mengaktifkan neuron sebagai penentu luaran dari jaringan syaraf tiruan.

#### 2. Pembagian Data

Pada penelitian ini digunakan data penggunaan beban listrik selama 6 tahun dari tanggal 1 Januari 2015 – 31 Desember 2020 dengan total *record* sebanyak 51168 *record* data. Dari keseluruhan data tersebut, data kemudian dibagi menjadi 2 yaitu data training dan data testing. Komposisi pembagian data pada penelitian dibagi menjadi 4 pembagian data yang secara umum. Untuk mengetahui komposisi pembagian data terbaik, maka dilakukan uji coba menggunakan model uji coba yang terdiri atas 1 input layer yang terdiri dari 24 unit masukan, 1 hidden layer dengan menggunakan 7 node dan 1 output layer yang terdiri atas 24 unit keluaran. Maka didapatkan hasil uji coba komposisi pembagian data yang dapat dilihat pada tabel 1 sebagai berikut.

Tabel 1. Uji Coba Pembagian Data

Pembagian Data (%)	Epoch	MSE
50-50	8	0.0027186
60-40	4	0.0025082
70-30	8	0.0026616
80-20	9	0.0029856

Berdasarkan hasil uji coba pada table 1, komposisi pembagian data 60% data training dan 40% data testing merupakan komposisi terbaik dengan MSE terkecil sebesar 0.0025082 dengan epoch 4. Berdasarkan hasil tersebut, peneliti menggunakan komposisi pembagian data 60% data training dan 40% data testing pada penelitian ini.

#### 3. Penentuan Arsitektur

Dalam arsitektur jaringan syaraf tiruan terbagi menjadi 3 lapisan, yang terdiri atas *input layer*, *hidden layer*, dan *output layer*. Pada penelitian ini *input layer* akan berisi 24 unit masukan. Penggunaan *hidden layer* yang akan diuji coba terdapat 11 model uji dengan variasi unit pengolahan pada *hidden layer* yang terdiri

dari 2 hingga 12 unit pengolahan. *Output layer* berisi 24 unit keluaran berupa penggunaan beban untuk keesokan harinya ( $X_{t+1}$ ).

### 3.2. Implementasi Model Jaringan Syaraf Tiruan

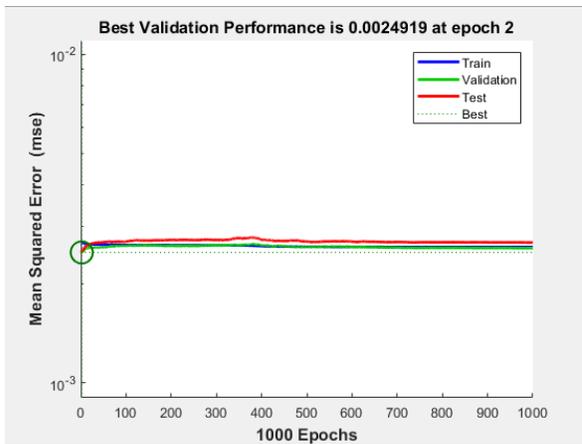
Pada implementasi jaringan syaraf tiruan dilakukan pelatihan dan pengujian model jaringan syaraf tiruan. Pada tahap pelatihan dilakukan pelatihan data untuk mengenali pola. Pada tahap pengujian dilakukan pengujian hasil pelatihan.

Untuk melakukan pelatihan dan pengujian model jaringan syaraf tiruan dibutuhkan fungsi pelatihan. Dalam menentukan fungsi pelatihan terbaik dilakukan uji coba menggunakan 1 hidden layer dengan 7 node. Adapun fungsi pelatihan yang akan diuji coba dapat dilihat pada tabel 2 berikut.

Tabel 2. Uji Coba Fungsi Pelatihan

Fungsi Pelatihan	MSE	Epoch
<i>Trainlm</i>	0.0025082	4
<i>Trainoss</i>	0.0026815	981
<i>Traincgb</i>	0.0026761	276
<i>Traingd</i>	0.019535	1000
<i>Traingdx</i>	0.0029555	992
<i>Trainr</i>	0.0028157	987
<i>Trainscg</i>	0.0026613	571
<i>Traingda</i>	0.0024577	162
<i>Traingdm</i>	0.0416	157
<i>Traincgp</i>	0.0026145	163
<i>Trainrp</i>	0.002975	151
<i>Trainbfg</i>	0.0026186	986
<i>Trainbr</i>	0.0030165	10
<i>Traincgf</i>	0.0023914	50

Setelah melakukan uji coba dengan beberapa fungsi pelatihan di dapatkanlah fungsi pelatihan *traincgf* sebagai fungsi pelatihan terbaik untuk penelitian ini. Hal ini dapat dilihat dari fungsi pelatihan *traincgf* yang memberikan MSE terbaik yaitu 0.0023914 pada epoch ke 50. Oleh karena itu, dengan menggunakan fungsi pelatihan *traincgf* maka didapatkan hasil pengujian training dan testing pada setiap model sebagai berikut.



Gambar 1. Grafik performance model dengan 2 node dalam hidden layer

Berdasarkan hasil pengujian data training dan testing pada setiap model didapatkan hasil pada tahap pelatihan berupa pola yang dapat dilihat pada grafik. Pada grafik, garis berwarna biru menyatakan hasil pelatihan, garis berwarna hijau menyatakan hasil validasi, garis berwarna merah menyatakan hasil pengujian dan garis putus-putus menyatakan hasil prediksi terbaik.

training dan data testing yang dapat dilihat pada table 3 sebagai berikut.

Tabel 3. Hasil Evaluasi Performa Model Prediksi

Model	Node	Training	Testing	Rata-rata Training	Rata-rata Testing	Total rata-rata
1	2	0.002616	0.004242	0.03681	0.050035	0.02343
2	3	0.002572	0.005008	0.03633	0.054913	0.02471
3	4	0.002594	0.005033	0.03637	0.055329	0.02483
4	5	0.00255	0.006039	0.03608	0.059874	0.02614
5	6	0.002482	0.007929	0.03562	0.065365	0.02785
6	7	0.0025	0.004735	0.03577	0.053472	0.02412
7	8	0.002558	0.005123	0.03633	0.054813	0.02471
8	9	0.002547	0.005339	0.03623	0.056583	0.02518
9	10	0.002477	0.005098	0.03564	0.054703	0.02448
10	11	0.002619	0.005339	0.03695	0.056583	0.02537
11	12	0.002588	0.004635	0.03644	0.052858	0.02413

Dari table 3 dapat dilihat bahwa model 1 merupakan model dengan hasil prediksi yang

Dimana dari hasil pola pada grafik semakin berdekatan dan semakin selaras satu sama lain maka menyatakan semakin baik hasil pelatihan dan pengujian. Dapat dilihat grafik model 1 dengan menggunakan 2 node merupakan model yang memberikan hasil grafik yang paling baik.

Dari hasil pengujian data training dan testing dapat dihasilkan performa validasi terbaik. Hasil validasi dapat dikatakan paling baik apabila bernilai paling kecil. Berdasarkan hasil diatas dapat diketahui pada gambar 1 grafik pada model 1 menunjukkan hasil performa validasi terbaik yang memiliki nilai paling kecil, yaitu sebesar 0.0024919 pada epoch 2.

### 3.3. Evaluasi Performa Model Prediksi

Evaluasi dilakukan untuk menentukan pola terbaik yang akan digunakan untuk memprediksi penggunaan beban listrik Parameter perhitungan *error* dihitung menggunakan rumus MSE pada data paling mendekati nilai yang sebenarnya. Oleh karena itu peneliti menggunakan model 1 untuk memprediksi beban listrik Sistem Mahakam.

### 3.4. Peramalan Beban listrik

Dari hasil *training* dan testing data maka didapatkan model peramalan terbaik dengan menggunakan model 1 dengan menggunakan 1 input layer dengan 24 masukan input, 1 hidden layer dengan 2 node dan 1 output layer dengan 24 unit keluaran. Maka didapatkanlah hasil peramalan untuk 1 Januari 2021 – 7 Januari 2021 dalam bentuk data yang telah di normalisasi (dalam bentuk range sigmoid biner) dapat dilihat pada table 4 berikut.

Tabel 4. Hasil Peramalan Masih Dalam Bentuk Data Normalisasi

Variabel	Pukul	Hasil prediksi						
		1-Jan-21	2-Jan-21	3-Jan-21	4-Jan-21	5-Jan-21	6-Jan-21	7-Jan-21
X1	01.00	0.75035	0.74643	0.36495	0.41365	0.45019	0.48329	0.51584
X2	02.00	0.80032	0.79479	0.36137	0.41521	0.45650	0.49433	0.53172
X3	03.00	0.83037	0.82380	0.47434	0.51795	0.55127	0.58175	0.61183
X4	04.00	0.67708	0.67117	0.33080	0.37465	0.40732	0.43678	0.46573
X5	05.00	0.78434	0.78267	0.42398	0.46747	0.50148	0.53296	0.56418
X6	06.00	0.52432	0.52006	0.27913	0.30485	0.32716	0.34886	0.37075

Variabel	Pukul	Hasil prediksi						
		1-Jan-21	2-Jan-21	3-Jan-21	4-Jan-21	5-Jan-21	6-Jan-21	7-Jan-21
X7	07.00	0.45960	0.46176	0.25070	0.27191	0.29125	0.31047	0.32999
X8	08.00	0.72479	0.72710	0.42042	0.44853	0.47623	0.50458	0.53366
X9	09.00	0.80400	0.80857	0.53893	0.56247	0.58664	0.61175	0.63763
X10	10.00	0.77276	0.77488	0.49010	0.51484	0.54035	0.56689	0.59426
X11	11.00	0.75406	0.75596	0.47235	0.49576	0.52097	0.54760	0.57518
X12	12.00	0.43620	0.43733	0.29032	0.30190	0.31489	0.32878	0.34322
X13	13.00	0.75244	0.75211	0.44534	0.47022	0.49743	0.52631	0.55625
X14	14.00	0.75892	0.76783	0.49314	0.51274	0.53669	0.56297	0.59049
X15	15.00	0.72610	0.73916	0.46223	0.48251	0.50674	0.53315	0.56076
X16	16.00	0.73931	0.74915	0.44992	0.47224	0.49848	0.52695	0.55667
X17	17.00	0.73235	0.74252	0.40385	0.43120	0.46122	0.49311	0.52620
X18	18.00	0.55597	0.56802	0.33301	0.35070	0.37133	0.39367	0.41697
X19	19.00	0.72949	0.72560	0.43136	0.45263	0.47833	0.50643	0.53584
X20	20.00	0.73478	0.73394	0.46008	0.47917	0.50298	0.52925	0.55681
X21	21.00	0.73168	0.73441	0.41680	0.44146	0.46946	0.49953	0.53082
X22	22.00	0.69760	0.69448	0.51312	0.53058	0.54708	0.56371	0.58069
X23	23.00	0.75930	0.75872	0.54655	0.56884	0.58843	0.60760	0.62697
X24	00.00	0.77717	0.77666	0.53142	0.55845	0.58128	0.60324	0.62530

Table 4.8 merupakan tabel data dalam bentuk data normalisasi (dalam bentuk *range sigmoid biner*). Maka dilakukan denormalisasi untuk merubah data yang masih dalam bentuk data normalisasi (dalam bentuk *range sigmoid biner*) ke nilai sebenarnya. Dengan menggunakan rumus denormalisasi maka didapatkan hasil pada table 5.

Tabel 5. Hasil Denormalisasi

Variabel	Pukul	Hasil prediksi						
		1-Jan-21	2-Jan-21	3-Jan-21	4-Jan-21	5-Jan-21	6-Jan-21	7-Jan-21
X1	01.00	367.274	366.28	269.62	281.96	291.22	299.61	307.85
X2	02.00	354.619	353.43	260.24	271.81	280.69	288.82	296.86
X3	03.00	345.371	343.65	252.01	263.44	272.18	280.17	288.06
X4	04.00	337.388	335.84	246.70	258.18	266.74	274.45	282.04
X5	05.00	338.086	337.67	249.00	259.75	268.16	275.94	283.66
X6	06.00	336.496	335.04	252.61	261.41	269.04	276.46	283.95
X7	07.00	316.243	316.97	246.19	253.30	259.79	266.23	272.78
X8	08.00	337.171	337.75	261.13	268.16	275.08	282.16	289.42
X9	09.00	365.117	366.57	280.86	288.34	296.03	304.01	312.23
X10	10.00	381.655	382.31	294.70	302.31	310.16	318.32	326.74
X11	11.00	394.483	395.09	304.76	312.22	320.25	328.73	337.51
X12	12.00	395.641	396.31	308.73	315.63	323.37	331.65	340.25
X13	13.00	405.143	405.04	312.45	319.96	328.17	336.89	345.92
X14	14.00	420.083	423.31	323.98	331.07	339.73	349.23	359.18
X15	15.00	411.476	415.97	320.67	327.65	335.99	345.08	354.58
X16	16.00	410.471	413.62	317.75	324.90	333.31	342.43	351.95
X17	17.00	397.311	400.00	310.59	317.81	325.73	334.15	342.89
X18	18.00	416.432	421.07	330.63	337.44	345.37	353.97	362.94
X19	19.00	468.259	466.98	370.22	377.22	385.67	394.91	404.58
X20	20.00	452.843	452.57	365.06	371.16	378.77	387.16	395.97
X21	21.00	447.484	448.25	358.93	365.86	373.74	382.19	390.99
X22	22.00	422.3	420.84	335.99	344.16	351.88	359.66	367.61
X23	23.00	392.147	391.93	311.52	319.96	327.39	334.65	342.00
X24	00.00	372.145	371.97	290.34	299.34	306.94	314.25	321.59

hasil denormalisasi data untuk peramalan pada tanggal 1 Januari 2021 – 7 Januari 2021. Kemudian dari tabel 4.10 diatas diperoleh rata-rata beban minimum pada pukul 07.00 dan beban maksimum pada pukul 19.00 selama 7 hari.

#### 4. Kesimpulan

Kesimpulan yang diperoleh dari hasil penelitian ini adalah :

1. Setelah melakukan uji coba model jaringan saraf tiruan untuk memprediksi penggunaan beban sistem mahakam menggunakan 11 model uji dengan 1 hidden layer dan komposisi pembagian data menggunakan 60% data training dan 40% data testing serta menggunakan fungsi pelatihan traincrgf. Didapatkanlah Model 1 dengan bentuk arsitektur jaringan syaraf tiruan yang terdiri atas 24 node pada input layer, 2 node pada hidden layer dan 24 node pada output layer merupakan model terbaik untuk melakukan prediksi penggunaan beban listrik.
2. MSE terbaik yang didapatkan dari model 1 adalah sebesar 0.002616 pada data training dan 0.004242 pada data testing. Maka dapat disimpulkan bahwa model 1 merupakan model prediksi dengan tingkat akurasi terbaik.
3. Berdasarkan hasil penelitian yang telah dilakukan, didapatkanlah model 1 sebagai model yang memiliki tingkat akurasi terbaik. Sehingga dapat diberikan rekomendasi dari hasil penelitian ini kepada PLN UP3B sebagai berikut:
  - a. Model ini dapat digunakan untuk memprediksi beban listrik harian, sehingga PLN UP3B dapat menyediakan kebutuhan beban listrik minimal berdasarkan beban maksimal dari hasil prediksi harian selama tujuh hari kedepan. Sebagai contoh PLN UP3B dapat menyediakan listrik harian sebesar 468.2589 MW pada tanggal 1 Januari 2021, 466.98 MW pada 2 Januari 2021, 370.22 MW pada 3 Januari 2021, 377.22 pada 4 Januari 2021, 385.67 MW pada 5 Januari, 394.91 MW pada 6 Januari 2021 dan 7 Januari 2021, dengan mempertimbangkan rata-rata error sebesar 0.02343 atau beban sebesar 169.1775 MW untuk meminimalisir kesalahan.

- b. PLN dapat menggunakan hasil peramalan beban harian atau mingguan sebagai bahan pertimbangan untuk melakukan proses penjadwalan mesin pembangkit listrik.

#### 4. Saran

Saran yang diperoleh dari hasil penelitian ini adalah :

1. Melakukan penelitian lanjutan dengan menggunakan jumlah data yang lebih banyak dengan menambahkan beberapa variabel inputan sehingga memiliki variasi penggunaan beban listrik yang lebih banyak. Misalnya mengumpulkan data penggunaan beban listrik industri atau perusahaan Kalimantan Timur yang cukup berpengaruh dengan naiknya penggunaan beban listrik.
2. Melakukan penelitian lanjutan dengan menggunakan variasi model uji yang lebih banyak seperti dengan menambahkan node pada hidden layer atau menambahkan dua hidden layer atau lebih untuk menambah variasi tingkat akurasi dari model jaringan syaraf tiruan.
3. Melakukan penelitian lanjutan dengan menggunakan algoritma yang berbeda. Misalnya menggunakan Algoritma Cascade-forward backprop, Competitive, Elman Backprop, Feed-forward distributed time delay, Feed-forward time delay, dan lain sebagainya.
4. Melakukan penelitian lanjutan dengan menggunakan data pada kasus lain. Misal prediksi penggunaan air bersih pada Kota Balikpapan.

#### 5. Daftar Pustaka

- [1] Fauzan Rais Arfizain, "Kesiapan Kalimantan Timur sebagai Ibukota dari Segi Pemenuhan Kebutuhan Listrik," *Kaltim Today*, Oct. 14, 2019.
- [2] Novi Abdi, "PLN sambungkan Sistem Mahakam dan Sistem Barito," *Antarakaltim*, 2018.
- [3] Pebrianto Elo Wicaksono, "Jaringan Terkoneksi, Pasokan Listrik Kalimantan Timur-Selatan Kian Andal," *Lipuran6*, 2018.
- [4] R. Dwisatya, M. R. Kirom, M. Si, A. G. Abdullah, and M. Si, "Prediksi Beban Listrik Jangka Pendek Menggunakan Algoritma Feed Forward Back Propagation dengan Mempertimbangkan Variasi Tipe Hari," *Electrans*, vol. 14, no. 1, pp. 34–40, 2016.
- [5] Muslimin, "Peramalan Beban Listrik Jangka Menengah Pada Sistem Kelistrikan Kota Samarinda," *Jiti*, vol. 14, no. 09, pp. 113–121, 2015.
- [6] Diyah Puspitaningrum, *Pengantar jaringan saraf tiruan*. Yogyakarta: Andi, 2006.
- [7] Julpan, E. B. Nababan, and M. Zarlis, "Bipolar Dalam Algoritma Backpropagation Pada," *J. Teknovasi*, vol. 02, pp. 103–116, 2015.
- [8] M. Yanto *et al.*, "Peramalan jumlah produksi air dengan algoritma backpropagation," pp. 172–177.
- [9] A. Hasim, "Prakiraan Beban Listrik Kota Pontianak Dengan Jaringan Syaraf Tiruan (Artificial Neural Network)," *Cent. Libr. Bogor Agric. Univ.*, p. 1, 2008.