

Peramalan Beban Listrik Kota Maros Berbasis Extreme Learning Machine (ELM)

Muhammad Zhahran Zhafirin Irawan
Departemen Teknik Elektro
Universitas Hasanuddin
Makassar, Indonesia
Zhahrann2@gmail.com

Yusri Syam Akil
Departemen Teknik Elektro
Universitas Hasanuddin
Makassar, Indonesia
yusakil@unhas.ac.id

Indar Chaerah Gunadin
Departemen Teknik Elektro
Universitas Hasanuddin
Makassar, Indonesia
indar@eng.unhas.ac.id

Abstract—Prakiraan beban listrik merupakan salah satu cara mengurangi resiko penyediaan tenaga listrik yang tidak stabil. Pada penulisan skripsi ini prakiraan beban listrik dilakukan dengan menggunakan jaringan syaraf tiruan metode *Extreme Learning Machine* (ELM). *Extreme Learning Machine* (ELM) adalah sebuah metode pembelajaran baru dalam jaringan syaraf tiruan dengan model single layer feedforward neural networks. Keakuratan dari metode Extreme Learning Machine (ELM) ini dapat di hitung dengan menggunakan *Mean Absolute Percentage Error* (MAPE). Berdasarkan implementasi yang dilakukan pada data beban listrik kota Maros diketahui bahwa dari dua fungsi aktivasi extreme learning machine yang di simulasi (linear dan logsig), fungsi aktivasi linear memberikan hasil prakiraan beban listrik harian yang lebih baik dengan nilai MAPE sebesar 5,44%.

Keywords— *Extreme Learning Machine, Jaringan Syaraf Tiruan, Beban Listrik, Prakiraan Beban Listrik.*

I. PENDAHULUAN

Tenaga listrik merupakan kebutuhan dasar bagi manusia dalam melakukan banyak aktivitasnya. Penggunaan listrik dari waktu ke waktu cenderung mengalami peningkatan yang besarnya tidak dapat ditentukan secara pasti. Peningkatan kebutuhan listrik tersebut mengharuskan pihak penyedia listrik dapat menyalurkan kebutuhan listrik konsumen agar stabilitas multibidang di masyarakat dapat terjamin. Adanya gangguan kekurangan pasokan listrik dapat mengganggu rutinitas kegiatan perekonomian di sisi masyarakat yang terkena dampaknya. Oleh karena itu reliabilitas dari pasokan listrik merupakan hal yang penting. Total daya yang dihasilkan pembangkit harus menyesuaikan kebutuhan daya yang ada pada konsumen. Untuk mengetahui seberapa besar daya yang harus disalurkan ke konsumen, pihak penyedia listrik memerlukan suatu perencanaan dengan menggunakan metode peramalan beban agar daya yang transmisikan tepat sasaran dan tepat ukuran. Maksud dari metode peramalan disini adalah untuk memperkirakan daya yang harus dikeluarkan oleh sisi pembangkitan agar efektifitas antara daya yang dihasilkan pembangkit dengan daya yang diterima konsumen lebih sempurna.

Banyak metode telah dikembangkan untuk peramalan beban listrik. Perusahaan penyedia listrik menggunakan suatu metode konvensional untuk meramalkan kebutuhan beban listrik di masa yang akan datang, dimana model dirancang berdasarkan hubungan antara beban listrik dengan faktor-faktor non linier yang mempengaruhi konsumsi beban seperti tingkat pertumbuhan penduduk, tingkat ekonomi masyarakat, cuaca pada periode tertentu, biaya pembangkitan energi listrik dan lain sebagainya. Dalam penelitian ini, diperkenalkan suatu metode *Extreme Learning Machine* (ELM) sebagai solusi untuk permasalahan dari factor-faktor non linier di atas yaitu peramalan beban listrik dilakukan berdasarkan pengenalan pola beban dalam periode jangka pendek pada semua hari di sistem kelistrikan. Dengan memperhatikan bagaimana pentingnya peramalan beban listrik harian atau jangka pendek terhadap operasi sistem tenaga listrik secara *real time* untuk mempertahankan keandalan serta efisiensi sistem tenaga listrik, maka dilakukan penelitian dengan judul “Prakiraan Beban Listrik Kota Maros Berbasis Extreme Learning Machine (ELM)”.

II. STUDI LITERATUR

A. Peramalan Beban Listrik

Peramalan beban listrik dalam pengoperasian sistem tenaga listrik sangat berguna dan berperan penting untuk melakukan pengaturan beban terutama secara *real time*. peramalan beban listrik memiliki tujuan sebagai berikut:

Peramalan Jangka Panjang (*Long-Term Forecasting*), merupakan peramalan beban listrik untuk rencana operasional jangka panjang atau tahunan yang memiliki tujuan untuk menentukan kapasitas serta ketersediaan unit pembangkitan, sistem transmisi, dan sistem distribusi.

Peramalan Jangka Menengah (*Mid-Term Forecasting*), merupakan peramalan beban listrik untuk rencana operasional bulanan atau mingguan yang memiliki tujuan untuk mempersiapkan kebutuhan energi bulanan, penjadwalan, pemeliharaan, dan operasional baik itu unit pembangkitan, sistem transmisi, maupun sistem distribusi.

Peramalan Jangka Pendek (*Short-Term Forecasting*), merupakan peramalan beban listrik

untuk rencana operasional harian yang memiliki tujuan untuk analisis, perencanaan, dan evaluasi neraca energi, serta studi perbandingan beban listrik hasil peramalan dengan aktual tiap jamnya (*real time*).

B. Jaringan Syaraf Tiruan

Jaringan syaraf tiruan adalah usaha untuk memodelkan pemrosesan informasi berdasarkan kemampuan sistem syaraf biologis yang ada pada manusia. Jadi, dapat kita simpulkan bahwa jaringan syaraf tiruan merupakan jaringan syaraf biologis dipandang dari sudut pandang pengolahan informasi. Hal ini akan memungkinkan kita untuk merancang model yang kemudian dapat disimulasikan dan dianalisis (Kusumadewi, Artificial Intelligence (teknik dan aplikasi), 2003)

Pada umumnya, JST dilatih (*trained*) agar input mengarah ke target output yang spesifik. Jadi jaringan dilatih terus menerus hingga mencapai kondisi di mana input sesuai dengan target yang telah ditentukan. Pelatihan di mana setiap input diasosiasikan dengan target yang telah ditentukan disebut pelatihan terarah (*supervised learning*) (Fikriya,2017).

C. Konsep Jaringan Syaraf Tiruan

Kerangka kerja dan skema interkoneksi dapat menggambarkan konsep dasar dari jaringan syaraf tiruan. Kerangka kerja jaringan saraf tiruan dapat dilihat dari jumlah lapisan (*layer*) dan jumlah *node* pada setiap lapisan, yaitu :

1. Lapisan Input (*Input Layer*)

Node-node di dalam lapisan *input* disebut unit-unit *Input*. Unit-unit *input* menerima *input* dari luar. *Input* yang dimasukkan merupakan penggambaran dari suatu masalah.

2. Lapisan Tersembunyi (*Hidden Layer*)

Node-node di dalam *hidden layer* disebut unit-unit tersembunyi unit-unit di dalam lapisan tersembunyi disebut unit-unit tersembunyi. Di mana outputnya tidak dapat secara langsung diamati.

3. Lapisan Output (*Output Layer*)


Node-node di dalam lapisan *output* disebut unit-unit *output*. Keluaran atau *output* dari lapisan ini merupakan *output* jaringan syaraf tiruan terhadap suatu permasalahan (Puspitaningrum,2006).

D. Arsitektur Jaringan Syaraf Tiruan

Jaringan syaraf tiruan dirancang menggunakan suatu aturan yang bersifat menyeluruh (*general rule*) dimana seluruh model jaringan memiliki konsep dasar yang sama. Arsitektur jaringan syaraf tiruan memiliki 3 macam lapisan. Yaitu :

1. Jaringan dengan Lapisan Tunggal (Single Layer Network)


Jaringan dengan lapisan tunggal hanya memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini hanya menerima *input* kemudian secara langsung akan mengolahnya menjadi *output* tanpa harus melalui lapisan *hidden*.



Gambar 1. Jaringan Syaraf Tiruan dengan Lapisan Tunggal

2. Jaringan dengan Banyak Lapisan (Multilayer Network)


Jaringan dengan lapisan jamak memiliki ciri khas tertentu yaitu memiliki 3 jenis lapisan yakni lapisan input, lapisan output, dan lapisan tersembunyi. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih kompleks dibandingkan jaringan dengan lapisan tunggal. Namun, proses pelatihan sering membutuhkan waktu yang cenderung lama (Ubay, 2012)



Gambar 2. Jaringan Syaraf Tiruan dengan Banyak Lapisan


3. Jaringan dengan Lapisan Kompetitif

Umumnya, hubungan antar *neuron* pada lapisan kompetitif ini tidak diperlihatkan pada diagram arsitektur.



Gambar 3. Jaringan Syaraf Tiruan dengan Lapisan Kompetitif

E. Struktur Jaringan Syaraf Tiruan Extreme Learning Machine (ELM)



Gambar 4. Model Extreme Learning Machine (ELM)

Jaringan Syaraf Tiruan *Extreme Learning Machine* (ELM) merupakan jaringan syaraf tiruan yang menggunakan struktur jaringan multi layer. Dapat dilihat pada Gambar 2.8 sebuah model jaringan syaraf tiruan *Extreme Learning Machine* (ELM) dengan m neuron input, n neuron hidden layer dan fungsi aktivasi $g(x)$. Misalkan $x = [x_1, x_2, x_3, \dots, x_n]$ dengan merupakan nilai input pada jaringan tersebut, H merupakan matriks bobot penghubung input layer dan hidden layer maka matriks H mempunyai ukuran $m \times n$. Penentuan nilai elemen-elemen matriks tersebut dilakukan secara random. Kemudian setiap nilai input tersebut diproses pada hidden layer menggunakan fungsi aktivasi sigmoid biner, dan nilai tersebut dihimpun dalam sebuah matriks H dengan ordo $m \times n$.

F. Evaluasi Kinerja Model


Mean Absolute Percentage Error (MAPE), *Mean Absolute Percentage Error* (MAPE) dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, merata-rata kesalahan persentase absolut tersebut. *Mean Absolute Percentage Error* (MAPE) mengindikasikan seberapa besar kesalahan prediksi yang dibandingkan dengan nilai nyata.

$$MAPE = \frac{1}{n} \sum_{i=1}^x \left| \frac{y - y_i}{y_i} \right| \times 100\% \quad (1)$$

III. METODOLOGI PERAMALAN

A. Tahapan Penelitian

Dalam melakukan skripsi ini yakni meramalkan beban listrik dibagi dalam tahapan-tahapan yang dilakukan secara berurut disusun secara sistematis dengan tujuan mendapatkan hasil yang sesuai dengan teori. Tahapan-tahapan penelitian tersebut secara garis besar digambarkan dalam alur diagram penelitian seperti berikut :



Gambar 5. Metode Pengerjaan Penelitian

B. Tahapan Penelitian

Dalam melakukan skripsi ini meramalkan beban listrik dibagi dalam tahapan-tahapan yang dilakukan

secara berurut disusun secara sistematis dengan tujuan mendapatkan hasil yang sesuai dengan teori, yaitu :

1. Tahap Inisiasi

Inisiasi merupakan tahap pertama dalam penelitian ini. Dalam tahap ini dilakukan pengambilan dan analisis data serta melakukan studi literatur pendukung.

2. Tahap Persiapan dan Perancangan Model

Setelah menentukan tujuan penelitian dan pengambilan data pada tahap sebelumnya, selanjutnya dilakukan persiapan data dan perancangan model.

3. Tahap Prediksi dan Analisa

Setelah dilakukan proses pengolahan data dan perancangan model yang sesuai, selanjutnya dilakukan proses prediksi menggunakan data dan model yang telah dikembangkan pada tahap sebelumnya.

4. Penarikan Kesimpulan

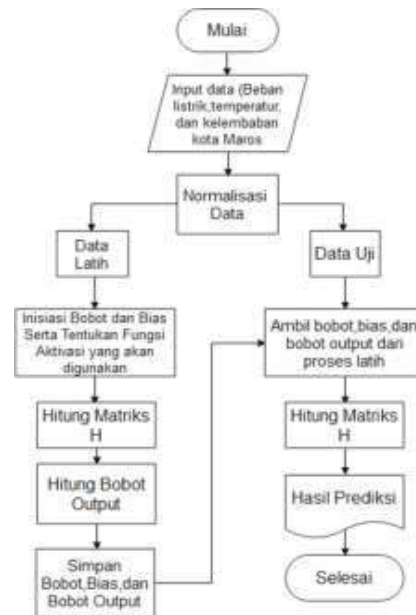
Penarikan kesimpulan dilakukan dengan memperhatikan hasil dari analisa prakiraan beban listrik harian di kota Maros. Kesimpulan yang ditarik apakah metode *Extreme Learning Machine* (ELM) dapat digunakan untuk melakukan prakiraan beban listrik harian di kota Maros dengan unjuk kerja yang baik

5. Penyusunan Laporan

Seluruh tahapan yang dilakukan hingga menghasilkan data yang diinginkan didokumentasikan dalam sebuah laporan.

C. Alur Penelitian

Adapun langkah-langkah penelitian ini digambarkan dalam diagram alir (*flowchart*) pada Gambar 4.



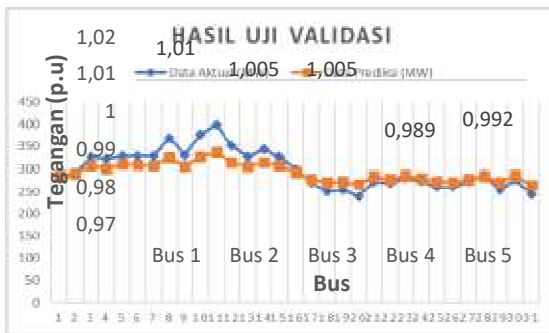
Gambar 6. Metode Extreme Learning Machine

IV. HASIL DAN PEMBAHASAN

A. Hasil Perbandingan Fungsi Aktivasi

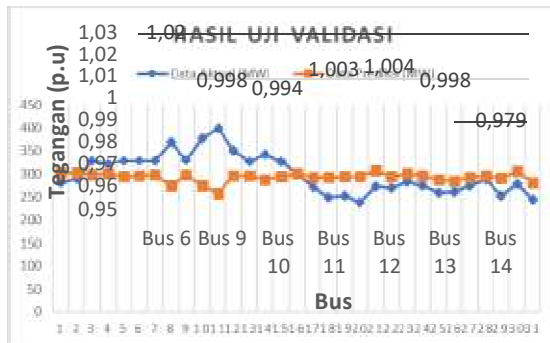
Pada penelitian ini digunakan dua fungsi aktivasi berbeda yang bertujuan untuk melihat perbandingan nilai *Mean Absolute Percentage Error* (MAPE) atau error yang dihasilkan oleh jaringan syaraf tiruan *Extreme Learning Machine* (ELM). Berikut ini adalah ilustrasi hasil pelatihan terhadap model *extreme learning machine* yang dibangun dengan menerapkan dua fungsi aktivasi yaitu fungsi aktivasi linear dan fungsi aktivasi sigmoid biner :

1. Grafik Fungsi Aktivasi Linear



Gambar 6. Grafik hasil uji validasi dengan fungsi aktivasi linear

2. Grafik Fungsi Aktivasi Logsig



Gambar 7. Grafik hasil uji validasi dengan fungsi aktivasi logsig

Setelah melakukan training dan testing dengan menerapkan dua fungsi aktivasi yang berbeda didapat bahwa *extreme learning machine* dengan fungsi aktivasi linear memberikan keluaran yang lebih baik dengan menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) 5,4454% dibandingkan dengan *extreme learning machine* dengan fungsi aktivasi sigmoid biner yang memberikan keluaran dengan nilai *Mean Absolute Percentage Error* (MAPE) 11,0165%. Hal ini disebabkan karena fungsi sigmoid biner (logsig) merupakan suatu fungsi non-linear dan fungsi ini lebih sering digunakan untuk metode backpropagation sedangkan pada penelitian kali ini menggunakan

metode feedforwards sehingga menghasilkan error yang lebih besar.

B. Hasil Uji Antara Variabel

1. Grafik Variabel Suhu



Gambar 8. Grafik hasil uji validasi menggunakan variabel suhu

2. Grafik Variabel Kelembapan



Gambar 9. Grafik hasil uji validasi menggunakan variabel kelembapan

Setelah melakukan uji validasi menggunakan 2 variabel yang berbeda dapat dilihat bahwa kedua variabel menunjukkan hasil uji validasi yang baik dengan nilai rata-rata *Mean Absolute Percentage Error* (MAPE) 5,708% untuk variabel suhu dan 5,975% untuk variabel kelembapan.

C. Hasil Uji Validasi Antara Variabel Dengan Fungsi Linear

1. Variabel Suhu

Tabel 1. Hasil prakiraan beban listrik harian (suhu)

Tanggal	Data Aktual (MW)	Data Prediksi (MW)	MAPE
01/12/2020	280,879	281,676	0,284
02/12/2020	289,212	285,722	1,207
03/12/2020	327,670	304,248	7,148
04/12/2020	322,056	301,401	6,413
05/12/2020	328,108	304,550	7,180
06/12/2020	328,113	304,484	7,201

07/12/2020	328,742	304,720	7,307
08/12/2020	369,760	324,323	12,288
09/12/2020	330,381	305,307	7,589
10/12/2020	377,356	327,901	13,106
11/12/2020	398,422	338,096	15,141
12/12/2020	350,984	315,257	10,179
13/12/2020	326,480	303,628	6,999
14/12/2020	342,479	311,331	9,095
15/12/2020	326,958	303,859	7,065
16/12/2020	299,207	290,367	2,955
17/12/2020	271,643	277,124	2,018
18/12/2020	250,366	267,009	6,647
19/12/2020	253,388	268,423	5,934
20/12/2020	238,577	261,339	9,541
21/12/2020	273,208	278,039	1,768
22/12/2020	270,094	276,422	2,343
23/12/2020	281,778	282,064	0,102
24/12/2020	274,800	278,604	1,384
25/12/2020	260,154	271,532	4,373
26/12/2020	260,482	271,622	4,277
27/12/2020	273,540	277,973	1,620
28/12/2020	287,076	284,441	0,918
29/12/2020	253,119	268,247	5,977
30/12/2020	278,010	280,358	0,845
31/12/2020	244,234	263,866	8,038
Rata-Rata MAPE			5,708

2. Variabel Kelembapan

Tabel 2. Hasil prakiraan beban listrik harian (Kelembapan)

Tanggal	Data Aktual (MW)	Data Prediksi (MW)	MAPE
01/12/2020	280,879	285,572	1,671
02/12/2020	289,212	288,697	0,178
03/12/2020	327,670	305,998	6,614
04/12/2020	322,056	300,768	6,610
05/12/2020	328,108	309,649	5,626
06/12/2020	328,113	308,123	6,093
07/12/2020	328,742	306,330	6,817
08/12/2020	369,760	324,503	12,240
09/12/2020	330,381	304,649	7,788
10/12/2020	377,356	326,693	13,426
11/12/2020	398,422	336,816	15,463
12/12/2020	350,984	313,211	10,762
13/12/2020	326,480	305,794	6,336
14/12/2020	342,479	313,819	8,368
15/12/2020	326,958	307,174	6,051

16/12/2020	299,207	291,490	2,579
17/12/2020	271,643	277,613	2,198
18/12/2020	250,366	270,634	8,095
19/12/2020	253,388	271,924	7,315
20/12/2020	238,577	266,392	11,659
21/12/2020	273,208	283,534	3,780
22/12/2020	270,094	278,191	2,998
23/12/2020	281,778	285,058	1,164
24/12/2020	274,800	279,735	1,796
25/12/2020	260,154	271,990	4,549
26/12/2020	260,482	271,007	4,041
27/12/2020	273,540	278,160	1,689
28/12/2020	287,076	283,644	1,195
29/12/2020	253,119	271,028	7,075
30/12/2020	278,010	284,932	2,490
31/12/2020	244,234	265,154	8,565
Rata-Rata MAPE			5,975

Dapat diketahui nilai *Mean Absolute Percentage Error* (MAPE) rata-rata prakiraan beban listrik harian bulan Desember 2020 menggunakan variabel suhu dengan fungsi aktivasi linear yaitu 5,708%, sedangkan prakiraan beban listrik harian bulan Desember 2020 menggunakan variabel kelembapan dengan fungsi aktivasi linear memiliki nilai *Mean Absolute Percentage Error* (MAPE) rata-rata yaitu 5,975.

D. Hasil Uji Validasi Fungsi Aktivasi Linear

Tabel 3. Hasil prakiraan beban listrik harian

Tanggal	Data Aktual (MW)	Data Prediksi (MW)	MAPE
01/12/2020	280,879	286,169	1,883
02/12/2020	289,212	289,342	0,045
03/12/2020	327,670	306,653	6,414
04/12/2020	322,056	301,153	6,490
05/12/2020	328,108	310,497	5,368
06/12/2020	328,113	308,842	5,873
07/12/2020	328,742	306,917	6,639
08/12/2020	369,760	324,836	12,149
09/12/2020	330,381	304,874	7,720
10/12/2020	377,356	326,881	13,376
11/12/2020	398,422	337,099	15,392
12/12/2020	350,984	313,473	10,687
13/12/2020	326,480	306,382	6,156
14/12/2020	342,479	314,409	8,196
15/12/2020	326,958	307,772	5,868
16/12/2020	299,207	291,840	2,462
17/12/2020	271,643	277,994	2,338
18/12/2020	250,366	271,261	8,346

19/12/2020	253,388	272,485	7,537
20/12/2020	238,577	267,040	11,930
21/12/2020	273,208	284,250	4,042
22/12/2020	270,094	278,662	3,172
23/12/2020	281,778	285,569	1,346
24/12/2020	274,800	280,051	1,911
25/12/2020	260,154	272,264	4,655
26/12/2020	260,482	271,156	4,098
27/12/2020	273,540	278,438	1,790
28/12/2020	287,076	283,822	1,133
29/12/2020	253,119	271,500	7,262
30/12/2020	278,010	285,646	2,747
31/12/2020	244,234	265,431	8,679
Rata-Rata MAPE			5,4454

23/12/2020	281,778	300,851	6,769
24/12/2020	274,800	295,265	7,447
25/12/2020	260,154	286,736	10,218
26/12/2020	260,482	284,320	9,152
27/12/2020	273,540	292,636	6,981
28/12/2020	287,076	296,308	3,216
29/12/2020	253,119	291,033	14,979
30/12/2020	278,010	304,510	9,532
31/12/2020	244,234	280,435	14,822
Rata-Rata MAPE			11,0165

E. Hasil Uji Validasi Fungsi Aktivasi Logsig

Tabel 4. Hasil prakiraan beban listrik harian

Tanggal	Data Aktual (MW)	Data Prediksi (MW)	MAPE
01/12/2020	280,879	302,810	7,808
02/12/2020	289,212	301,835	4,365
03/12/2020	327,670	297,188	9,303
04/12/2020	322,056	299,942	6,866
05/12/2020	328,108	294,246	10,320
06/12/2020	328,113	294,702	10,183
07/12/2020	328,742	296,372	9,847
08/12/2020	369,760	274,830	25,673
09/12/2020	330,381	297,939	9,819
10/12/2020	377,356	274,741	27,193
11/12/2020	398,422	257,315	35,416
12/12/2020	350,984	295,887	15,698
13/12/2020	326,480	296,233	9,264
14/12/2020	342,479	287,933	15,927
15/12/2020	326,958	294,206	10,017
16/12/2020	299,207	299,910	0,235
17/12/2020	271,643	291,759	7,405
18/12/2020	250,366	292,692	16,906
19/12/2020	253,388	293,954	16,010
20/12/2020	238,577	294,400	23,398
21/12/2020	273,208	306,598	12,222
22/12/2020	270,094	294,641	9,088

Setelah proses denormalisasi dilakukan, dapat diketahui nilai *Mean Absolute Percentage Error* (MAPE) rata-rata prakiraan beban listrik harian bulan Desember 2020 dengan fungsi aktivasi linear yaitu 5,4454%, dengan nilai *Mean Absolute Percentage Error* (MAPE) terendah pada tanggal 2 Desember 2020 sebesar 0,045% dan nilai *Mean Absolute Percentage Error* (MAPE) tertinggi pada tanggal 11 Desember 2020 sebesar 15,392%, namun secara umum prakiraan beban listrik harian bulan Desember 2020 menunjukkan nilai *Mean Absolute Percentage Error* (MAPE) dibawah 10% secara dominan.

Sedangkan nilai *Mean Absolute Percentage Error* MAPE rata-rata prakiraan beban listrik harian bulan Desember 2020 dengan fungsi aktivasi sigmoid biner yaitu 11,0165%, dengan nilai *Mean Absolute Percentage Error* (MAPE) terendah pada tanggal 16 Desember 2020 sebesar 0,235% dan nilai *Mean Absolute Percentage Error* (MAPE) tertinggi pada tanggal 11 Desember 2020 sebesar 35,416%, dan dapat kita lihat secara umum prakiraan beban listrik harian bulan Desember 2020 dominan menunjukkan nilai *Mean Absolute Percentage Error* (MAPE) diatas 10%. Sehingga dapat kita simpulkan bahwa prakiraan beban listrik harian bulan Desember 2020 dengan fungsi aktivasi linear menunjukkan unjuk kerja yang lebih baik dibandingkan dengan menggunakan fungsi aktivasi sigmoid biner.

V. KESIMPULAN

1. Jaringan Syaraf Tiruan Metode Extreme Learning Machine (ELM) dapat diterapkan untuk melakukan prakiraan beban listrik. Proses yang digunakan antara lain training data, testing data training, dan uji validasi data.
2. Penelitian ini mengembangkan model prakiraan beban listrik berbasis extreme learning machine dengan studi kasus kota Maros. Dari dua fungsi aktivasi extreme learning machine yang di simulasi (linear dan logsig), fungsi aktivasi linear memberikan hasil prakiraan beban listrik harian yang lebih baik dengan nilai MAPE rata-rata

sebesar 5,44% untuk bulan Desember 2020. Besar nilai MAPE ini menunjukkan bahwa model peramalan yang dibuat memiliki unjuk kerja yang baik.

Referensi

- [1] Agustina, I. (2010). *Penerapan Metode Extreme Learning Machine untuk Peramalan Permintaan*. Surabaya: Institut Teknologi Sepuluh November.
- [2] Dash, S. K., & Patel, D. (2015). Short-term Electric Load Forecasting using Extreme Learning Machine-A case study of Indian Power Market. *Communication and Information Technology Conference (PCITC)*. India: IEEE.
- [3] Fachrony, A., Cholissodin, I., & Santoso, E. (2018). Implementasi Algoritme Extreme Learning Machine (ELM) untuk Prediksi Beban Pemanasan dan Pendinginan Bangunan. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3043-3049.
- [4] Fardani, D. P., Wuryanto, E., & Werdiningsih, I. (2015). Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode Extreme Learning Machine (Studi Kasus:Poli Gigi RSUD Dr.Wahidin Sudiro Husodo Mojokerto). *Journal of Information Systems Engineering and Business Intelligence*, 33-40.
- [5] Fikriya, Z. A., Irawan, M. I., & Soetrisno. (2017). Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital. *Jurnal Sains dan Seni ITS vol.6,No.1*, 2337-3520.
- [6] Harum, L. H., Hidayat, N., & Dewi, R. K. (2018). Implementasi Metode Extreme Learning Machine (ELM) untuk Memprediksikan Penjualan Roti. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5040-5048.
- [7] Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme Learning Machine: Theory and Applications. *Neurocomputing*, 489-501.
- [8] Humaini, Q. (2015). *Jaringan Syaraf Tiruan Extreme Learning Machine (ELM) untuk Memprediksi Kondisi Cuaca di Wilayah Malang*. Malang: Universitas Islam Negeri Maulana Malik Ibrahim Malang.
- [9] Khair, A. (2011). *Peramalan Beban Listrik Jangka Pendek Menggunakan Kombinasi Metode Autoagressive Integrated Moving Average (ARIMA) dengan Regresi Linear Antara Suhu dan Daya Listrik*. Depok: Universitas Indonesia.
- [10] Kusumadewi, S. (2003). *Artificial Intellegence (teknik dan aplikasi)*. Yogyakarta: Graha Ilmu.
- [11] Kusumadewi, S. (2003). *Artificial Intelligence: Menyamai Kecerdasan Buatan Ilahi*. Yogyakarta: Graha Ilmu.
- [12] Lesnussa, Y. A., Sinay, L. J., & Idah, M. R. (2017). Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Penyebaran Penyakit Demam Berdarah Dengue (DBD) di Kota Ambon. *Journal Matematika Integratif*, 63-72.
- [13] Najar, A. M. (2018). *Application of extreme learning machine method for dengue outbreak risk level prediction based on weather condition (case study : dki jakarta region)*. Surabaya: Institut Teknologi Sepuluh November.
- [14] Nurvianti, I., Setiawan, B. D., & Bachtiar, F. A. (2019). Perbandingan Peramalan Jumlah Penumpang Keberangkatan Kereta Api di DKI Jakarta Menggunakan Metode Double Exponential Smoothing dan Triple Exponential Smoothing. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5257-5263.
- [15] Puspitaningrum, D. (2006). *Pengantar Jaringan Syaraf Tiruan*. Yogyakarta : Andi.
- [16] Rojas, R. (1996). *Neural Networks*. Berlin: Springer-Verlag.
- [17] Shereef, I., & Baboo, D. S. (2011). A New Weather Forecasting Technique using Back Propagatuib Neural Network with Modified Levenberg-Marquardt Algorithm for Learning. *International Journal of Computer Science Issues*, 153-160.
- [18] Siang, J. J. (2009). *Jaringan Syaraf Tiruan & Pemrogramannya Menggunakan Matlab*. Yogyakarta: Andi.
- [19] Ubay, M. S. (2012). *Peramalan Harga Saham dengan Menggunakan Jaringan Syaraf Tiruan Metode Extreme Learning Machine*. Malang: Universitas Airlangga .