

PERAMALAN BEBAN JANGKA PENDEK SISTEM KELISTRIKAN KOTA BATU MENGGUNAKAN DEEP LEARNING LONG SHORT-TERM MEMORY

Heru Purnomo, Hadi Suyono^{*)}, Rini Nur Hasanah

Jurusan Teknik Elektro, Fakultas Teknik, Universitas Brawijaya
Jalan MT Haryono 167 Malang 65145, Indonesia

^{*)}E-mail: hadis@ub.ac.id

Abstrak

Akses terhadap listrik mempunyai dampak signifikan-positif terhadap pertumbuhan ekonomi, baik bagi mereka yang tinggal di area pedesaan maupun perkotaan. Untuk mendukung pertumbuhan ekonomi, perbaikan serta peningkatan sektor kelistrikan wajib terus-menerus diupayakan. Sejalan dengan upaya memperbaiki dan meningkatkan layanan dan ketersediaan di sektor kelistrikan, penelitian ini ditujukan untuk meramalkan beban listrik jangka pendek di wilayah Kota Batu, Indonesia. Dengan didasarkan pada data yang mencakup data beban puncak per penyulang per hari, data jumlah pelanggan per kategori tarif per hari, serta data cuaca per hari, selama satu tahun penuh di 2020, metode *deep-learning long short-term memory* (LSTM) dimanfaatkan untuk menyimulasikan berbagai skenario pembagian data latih dan data uji. Analisis peramalan beban menggunakan metode *autoregressive integrated moving average* (ARIMA) digunakan sebagai pembandingan. Dengan skenario pembagian data latih dan data uji terdiri dari 50%–50%, 60%–40%, 70%–30%, 80%–20%, dan 90%–10% dengan jumlah iterasi 100, penggunaan metode *deep learning* LSTM menghasilkan nilai RMSE (*Root Mean Square Error*) sebesar 0,03 yang lebih baik dibandingkan nilai 0,07 yang diperoleh dengan metode ARIMA. Dapat disimpulkan bahwa secara umum implementasi metode *deep learning* LSTM memberikan keunggulan dalam tingkat akurasi dibandingkan dengan metode ARIMA, sehingga menjamin hasil yang lebih akurat dalam peramalan beban konsumsi listrik jangka pendek di Kota Batu.

Kata kunci: ARIMA, Deep Learning LSTM, peramalan beban

Abstract

Access to electricity has a significant-positive impact on economic growth, both for those living in rural and urban areas. To support economic growth, efforts must be continuously pursued to improve and enhance the electricity sector. In line with the efforts to enhance and improve the services and availability in the electricity sector, this study is aimed at forecasting short-term electricity loads in the Batu City area, Indonesia. Based on the data that includes the peak load data of each feeder per day, the data of the subscriber number of per tariff category per day, as well as the weather data per day, for a full year in 2020, the *deep-learning long short-term memory* (LSTM) method has been explored to simulate various scenarios of proportion sharing of the training data and test data. Load forecasting analysis using the *autoregressive integrated moving average* (ARIMA) method has been used as a comparison. Using the proportion sharing scenario of the training data and test data consisting of 50%–50%, 60%–40%, 70%–30%, 80%–20%, and 90%–10% with a total of 100 iterations, the implementation of the LSTM *deep learning* method resulted in an RMSE (*Root Mean Square Error*) value of 0.03 which was better than the 0.07 value obtained using the ARIMA method. It can be concluded that the implementation of the LSTM *deep learning* method provides an advantage in the level of accuracy compared to the ARIMA method, thereby ensuring more accurate results in forecasting short-term electricity consumption loads in Batu City.

Keywords: ARIMA, Deep Learning LSTM, Forecasting.

1. Pendahuluan

Akses terhadap energi listrik mempunyai dampak yang signifikan dan positif terhadap pertumbuhan ekonomi, baik bagi mereka yang tinggal di area pedesaan maupun perkotaan [1]. Untuk dapat terus mendukung pertumbuhan ekonomi, sektor penyedia kelistrikan dituntut untuk terus-

menerus mengupayakan perbaikan dan peningkatan layanannya, termasuk pemenuhan kebutuhan sumber daya listrik. Sejalan dengan upaya tersebut, banyak penelitian dilakukan untuk memperkirakan jumlah kebutuhan beban listrik yang harus disuplai oleh perusahaan penyedia energi listrik. Berbagai penelitian dilakukan untuk mendapatkan metode peramalan beban listrik yang akurat. Pengoperasian sistem daya listrik harus selalu

mempertimbangkan kenyataan bahwa tujuan pembangkitan daya listrik adalah untuk memenuhi kebutuhan pelanggan [2], sehingga informasi mengenai jumlah pelanggan setiap saatnya termasuk di masa yang akan datang sangat penting dalam pengoperasian sistem kelistrikan. Metode peramalan beban yang akurat sangat diperlukan [3].

Peramalan beban listrik merujuk pada penggunaan metode matematis tertentu untuk memproses data beban di masa lalu, dan kemudian secara sistematis memperkirakan beban di masa depan. Peramalan dilakukan dengan mempertimbangkan data dari beragam aspek terkait agar dapat dicapai tingkat akurasi yang memuaskan [4]. Tingkat akurasi dan keandalan peramalan beban listrik jangka pendek sangat menentukan tingkat kecepatan manuver penyulang pada situasi-situasi yang tidak terduga, efisiensi operasional jaringan distribusi, optimalisasi perencanaan manuver beban penyulang, dan efisiensi biaya perawatan harian [5].

Kota Batu sebagai salah satu kota wisata terkemuka di Indonesia karena potensi keindahan alamnya yang luar biasa, mengalami pertumbuhan ekonomi yang cukup cepat [6]. Pertumbuhan ekonomi yang seiring dengan pertumbuhan tingkat konsumsi daya listrik membutuhkan ketersediaan sumber daya listrik yang memadai. Penelitian ini ditujukan untuk meramalkan beban listrik jangka pendek di Kota Batu, agar rekomendasi dapat diberikan kepada pihak-pihak terkait untuk perencanaan pemenuhan kebutuhan listrik tersebut.

Penggunaan metode *deep learning long short-term memory* (LSTM) dikaji dalam penelitian ini untuk meramalkan beban listrik jangka pendek di Kota Batu. Metode *Deep Learning* mempunyai kelebihan dalam pencarian solusi yang akurat dan lebih baik, namun membutuhkan jeda waktu pencarian yang cukup lama [7]. Metode LSTM yang memiliki kemampuan generalisasi dan kemampuan *learning* yang lebih baik untuk himpunan data besar dan kecil, serta data *non-linear*, dapat dimanfaatkan untuk meningkatkan akurasi peramalan beban listrik jangka pendek [5].

Implementasi metode *deep learning* LSTM dibandingkan dengan salah satu metode yang banyak dipakai selama ini, yaitu metode *autoregressive integrated moving average* (ARIMA). Parameter pembandingan yang digunakan adalah nilai *Mean Absolute Percent Error* (MAPE) dan *Root Mean Square error* (RSME).

2. Metode

2.1. Peramalan Beban

Peramalan merupakan kegiatan yang bertujuan untuk memperkirakan kejadian yang akan terjadi di masa depan berdasarkan data masa lalu. Dalam melakukan peramalan diperlukan metode yang sesuai dengan data dan informasi

yang akan diramalkan agar dapat mencapai tujuan. Dalam pengoperasian sistem tenaga listrik, masalah peramalan beban merupakan masalah yang sangat penting, baik dari segi manajemen maupun dalam operasional perusahaan, sehingga perlu mendapatkan perhatian khusus. Peramalan beban berdasarkan waktu dapat dibagi menjadi beberapa kelompok seperti yang dijelaskan dalam [8] dan [9].

2.2. *Deep Learning Long Short-Term Memory* (LSTM)

Deep Learning merupakan salah satu cabang *Machine Learning* (ML), yang menggunakan *Deep Neural Network* untuk menyelesaikan permasalahan [10]. *Neural Network*, terinspirasi oleh cara kerja neuron dalam otak manusia [11]. Tiap *neuron* dalam otak manusia saling berhubungan dan informasi mengalir dari dan antar setiap *neuron* tersebut.

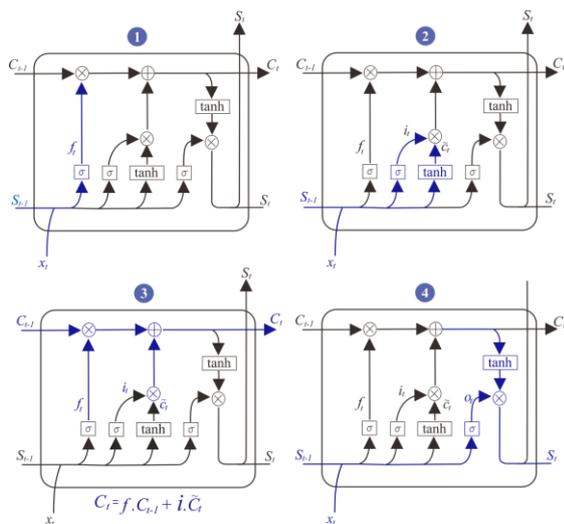
Dalam *Deep Learning*, jaringan terdiri dari beberapa *layer* yang merupakan kumpulan dari *node-node*. Suatu *node* menjadi tempat terjadinya perhitungan. Dibandingkan dengan *neural network*, pada *Deep Learning* terdapat lebih banyak *hidden layer*, yang dapat berjumlah lebih dari tiga *layer* (termasuk input dan output) atau bahkan hingga mencapai ratusan. Algoritma jaringan saraf *Deep Learning* tidak memerlukan informasi apapun terhadap data yang akan dipelajari. Algoritma dapat melakukan *tuning* (penyetelan) secara mandiri dan melakukan pemilihan model yang paling optimal.

LSTM sering digunakan untuk mengatasi kekurangan yang dijumpai pada jaringan syaraf berulang, yang berupa fenomena besarnya *gradient* yang menghilang. LSTM memiliki kemampuan generalisasi yang kuat, dan kemampuan *learning* yang baik untuk himpunan data besar dan kecil, sekaligus mempunyai banyak kelebihan dalam memproses data *non-linear*, yang dapat meningkatkan akurasi peramalan beban listrik jangka pendek [5]. LSTM dapat menggunakan ukuran data yang lebih besar dan menggunakan semua informasi data sebagai masukan, untuk membangun *deep network* [12].

LSTM memiliki tiga gerbang yang mengendalikan penggunaan dan memperbarui informasi teks terdahulu yaitu input gate, forget gate, dan output gate. Dalam memproses data masukan, LSTM menggunakan tahapan-tahapan seperti yang ditunjukkan pada Gambar 1, sedangkan diagram alir ditunjukkan pada Gambar 2.

Langkah pertama dimulai dari *forget gate* (f_t), Gerbang ini membaca nilai S_{t-1} dan X_t . Nilai dari *forget gate* adalah antara 0 dan 1. Informasi yang kurang dibutuhkan terhadap kasus yang dikelola akan dihilangkan menggunakan fungsi sigmoid (σ). Langkah kedua adalah informasi baru apa yang akan digunakan di bagian *cell state* (C_t). Proses ini mengalami dua bagian yaitu gerbang sigmoid (σ) memutuskan nilai apa yang akan diperbarui dan

menggunakan fungsi aktivasi *tanh* yang membentuk kandidat konteks baru (\bar{C}_t). Langkah ketiga yaitu dengan memperbarui nilai *cell state* lama (C_{t-1}) menjadi *cell state* baru (C_t). Nilai *cell state* lama (C_{t-1}) dikalikan dengan f_t . Kandidat konteks baru \bar{C}_t dikalikan dengan i_t untuk menyertakan seberapa banyak kandidat konteks baru. Kedua hasil tersebut ditambahkan. Langkah terakhir terdapat pada komponen *output gate*, dengan menjalankan sigmoid (σ) untuk menghasilkan nilai *output* (O_t) dan memproses *cell state* (C_t) pada aktivasi *tanh*. Setelah itu proses tersebut akan menghasilkan nilai S_t [13].



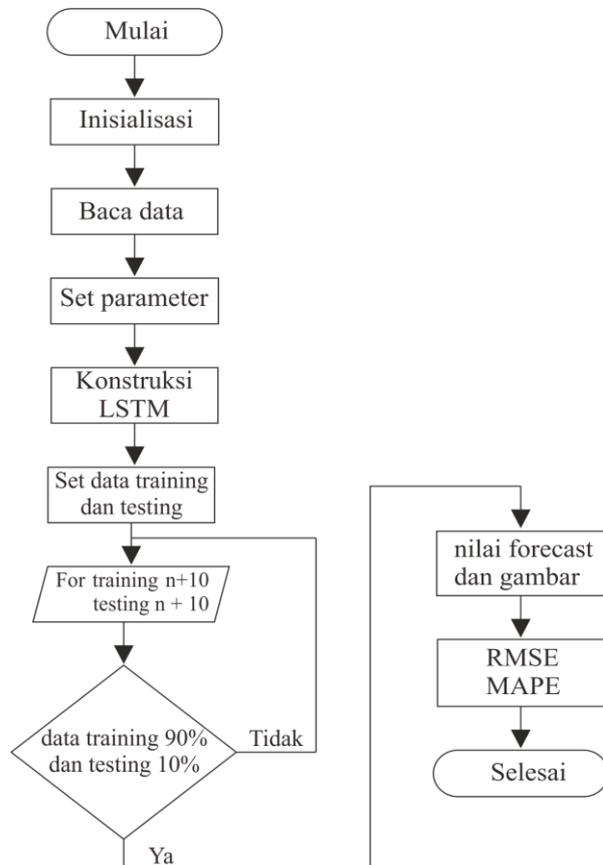
Gambar 1. Tahapan *deep learning* LSTM

2.3. Model Autoregressive Integrated Moving Average (ARIMA)

ARIMA merupakan suatu metode peramalan yang biasanya sangat baik digunakan untuk melakukan peramalan jangka pendek. Model ARIMA juga merupakan salah satu model yang digunakan dalam peramalan data time series yang bersifat non stasioner. Secara umum sering disebut sebagai model ARIMA (p,d,q) atau biasanya disebut sebagai ARIMA [13-15].

Model ARIMA secara penuh mengabaikan independen variabel dalam membuat prakiraan. ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan prakiraan jangka pendek yang akurat. ARIMA cocok digunakan jika observasi deret waktu (*time series*) secara statistik berhubungan satu sama lain (*dependent*). Pemodelan ARIMA merupakan metode yang fleksibel untuk berbagai macam data deret waktu, termasuk untuk menghadapi fluktuasi data musiman. Secara umum, model seasonal ARIMA dituliskan dengan notasi ARIMA (p,d,q) (P,D,Q)_s, yaitu dengan (p,d,q) bagian tidak musiman dari model, (P,D,Q) bagian musiman dari model dan s merupakan jumlah periode per musim. Penerapan metode ARIMA adalah dengan menggunakan pendekatan metode Box-Jenkins, yaitu

tahapan-tahapan yang diperlukan dalam menentukan parameter ARIMA serta pengujiannya, sebelum akhirnya digunakan sebagai model prakiraan selama beberapa waktu ke depan.



Gambar 2. Diagram alir metode *Deep Learning* LSTM

2.4. Kriteria Keabaikan Model

Pemilihan model terbaik pada kriteria *in sample* dan *out data sample* dapat dilakukan menggunakan perhitungan *Root Mean Square Error* (RMSE) yang dirumuskan sebagai berikut.

$$RMSE = \left(\frac{\sum (y_i - \hat{y}_i)^2}{n} \right)^{1/2} \quad (1)$$

Perhitungan kriteria pemilihan model terbaik dari data *out sample* juga dapat dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE merupakan suatu persentase kesalahan rata-rata absolut. Rumus umum dari MAPE dapat dituliskan sebagai berikut:

$$MAPE = \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\% \quad (2)$$

- y_i : nilai hasil observasi
- \hat{y}_i : nilai hasil prediksi
- i : urutan data pada database
- n : jumlah data

3. Hasil dan Analisis

Simulasi *forecasting* beban jangka pendek pada GI Sengkaling diambil sebagai kasus untuk menguji kemampuan metode *Deep Learning* LSTM. Kinerja metode ARIMA digunakan untuk perbandingan. Simulasi dilakukan secara bertahap dengan iterasi 100, mengikuti skenario pembagian data *training* dan data *testing* sebagai berikut

- (1) Simulasi dengan proporsi data *training* dan data *testing* 50%–50%, yang digunakan sebagai data *testing* yaitu data beban puncak per penyulang per hari di periode 2 Juli 2020–31 Desember 2020.
- (2) Simulasi dengan proporsi data *training* dan data *testing* 60%–40%, yang digunakan sebagai data *testing* yaitu data beban puncak per penyulang per hari di periode 8 Agustus 2020–31 Desember 2020.
- (3) Simulasi dengan proporsi data *training* dan data *testing* 70%–30%, yang digunakan sebagai data *testing* yaitu data beban puncak per penyulang per hari di periode 13 September 2020–31 Desember 2020.
- (4) Simulasi dengan proporsi data *training* dan data *testing* 80%–20%, yang digunakan sebagai data *testing* yaitu data beban puncak per penyulang per hari di periode 20 Oktober 2020–31 Desember 2020.
- (5) Simulasi dengan proporsi data *training* dan data *testing* 90%–10%, yang digunakan sebagai data *testing* yaitu data beban puncak per penyulang per hari di periode 24 November 2020–31 Desember 2020.

Hasil pengolahan data pada Penyulang Panorama ditunjukkan pada Tabel 1.

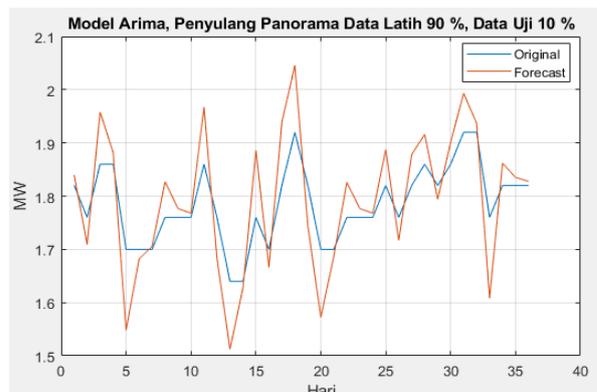
Tabel 1. Hasil pengolahan data Penyulang Panorama

Data	Metode	RMSE	MAPE
50 %	Arima	0.094397	4.0981
	Deep Learning	0.007306	3.3667
60 %	Arima	0.094077	3.9820
	Deep Learning	0.050983	2.1839
70 %	Arima	0.093388	3.8650
	Deep Learning	0.054102	2.4041
80 %	Arima	0.098819	3.9754
	Deep Learning	0.041866	1.7387
90 %	Arima	0.073624	3.2598
	Deep Learning	0.034388	1.6224

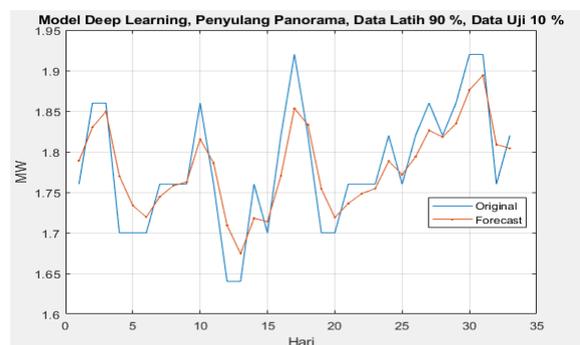
Dengan menggunakan jumlah iterasi sebanyak 100 kali, pada Tabel 1 ditunjukkan bahwa dengan menggunakan metode ARIMA dengan proporsi data *training* 50% dan data *testing* 50% diperoleh nilai RMSE sebesar 0,09 dan nilai MAPE sebesar 4,09. Hasil simulasi menggunakan metode *Deep Learning* memberikan nilai RMSE sebesar 0,07 dan nilai MAPE sebesar 3,366. Dengan perbandingan proporsi data *training* 90% dan data *testing* 10% diperoleh nilai RMSE sebesar 0,07 dan nilai MAPE sebesar 3,25 dengan metode ARIMA, dan nilai RMSE sebesar 0,03 dan nilai MAPE sebesar 1,62 dengan metode *Deep Learning*. Hasil simulasi metode ARIMA dan *Deep Learning* pada Penyulang Panorama juga menunjukkan bahwa semakin

banyak data *training* yang digunakan maka nilai RMSE dan MAPE akan semakin kecil / mendekati 0.

Hasil peramalan beban jangka pendek dalam bentuk kurva dapat dilihat pada Gambar 3 dan Gambar 4 secara berturut-turut menggunakan metode ARIMA dan *Deep Learning* pada Penyulang Panorama.



Gambar 3. Hasil *forecasting* menggunakan metode ARIMA pada Penyulang Panorama dengan proporsi data *training* 90% dan data *testing* 10%



Gambar 4. Hasil *forecasting* menggunakan metode *Deep Learning* pada Penyulang Panorama dengan proporsi data *training* 90% dan data *testing* 10%

Hasil terkait untuk Penyulang Wastra Indah ditunjukkan pada Tabel 2, sedangkan dalam bentuk kurva ditunjukkan pada Gambar 5 dan Gambar 6.

Seperti terlihat pada Tabel 2, dengan jumlah iterasi yang sama yaitu 100 kali, penggunaan metode ARIMA untuk simulasi peramalan beban pada penyulang Wastra Indah menggunakan data *training* 50% dan data *testing* 50% menghasilkan nilai RMSE sebesar 0,47 dan nilai MAPE sebesar 10,3. Hasil simulasi menggunakan metode *Deep Learning* menghasilkan nilai RMSE sebesar 0,48 dan nilai MAPE sebesar 4,10. Dengan proporsi data *training* 90% dan data *testing* 10%, penggunaan metode ARIMA menghasilkan nilai RMSE sebesar 0,07 dan nilai MAPE sebesar 2,70, sedangkan menggunakan metode *Deep*

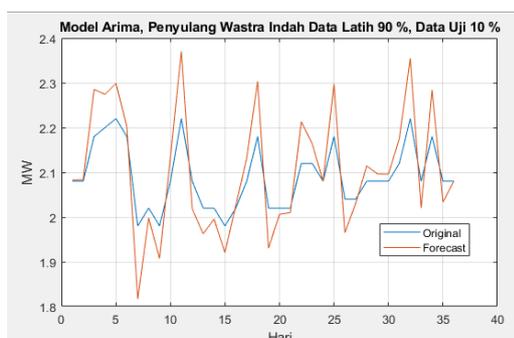
Learning menghasilkan nilai RMSE sebesar 0,12 dan nilai MAPE sebesar 4,87.

Tabel 2. Hasil pengolahan data Penyulang Wastra Indah

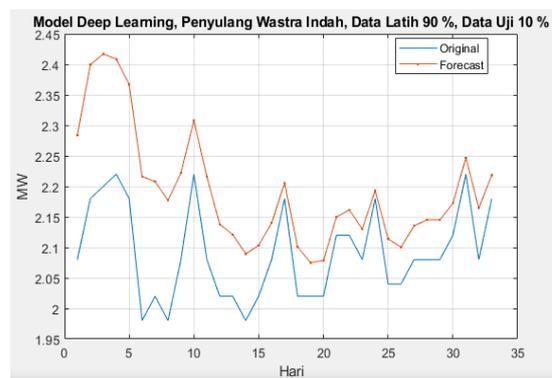
Data	Metode	RMSE	MAPE
50 %	Arima	0.47304	10.3198
	Deep Learning	0.48578	4.10060
60 %	Arima	0.47460	10.8571
	Deep Learning	0.04432	11.1295
70 %	Arima	0.38970	8.57610
	Deep Learning	0.26592	5.83320
80 %	Arima	0.41915	8.81990
	Deep Learning	0.28529	6.11480
90 %	Arima	0.07237	2.70500
	Deep Learning	0.12085	4.87460

Hasil simulasi metode Arima dan *Deep Learning* pada penyulang Wastra Indah dengan data *training* 70% dan data *testing* 30% memberikan nilai RMSE sebesar 0,38 dan 0,26 dan nilai MAPE sebesar 8,57 dan 5,83 berturut-turut. Hasil simulasi metode Arima dan *Deep Learning* pada penyulang Wastra Indah dengan data *training* 80% dan data *testing* 20% menghasilkan nilai RMSE sebesar 0,41 dan 0,28 dan nilai MAPE sebesar 8,81 dan 6,11 untuk masing-masing metode.

Perlu diperhatikan pula bahwa hasil simulasi menggunakan data penyulang Wastra Indah dengan proporsi data *training* 80% dan data *testing* 20% menunjukkan nilai RMSE dan MAPE yang lebih besar daripada ketika menggunakan proporsi data *training* 70% dan *testing* 30%. Hal ini disebabkan karena pada empat hari di bulan September dan November, dan satu hari di bulan Oktober tahun 2020, terjadi kenaikan beban puncak dari 3,1 MW menjadi 4,1 MW, yang jauh lebih besar dari beban puncak rata – rata sebesar 2,24 MW pada periode September sampai dengan November 2020. Terjadinya beberapa lonjakan beban puncak pada rentang waktu bulan September sampai dengan November 2020 mempengaruhi nilai data *testing* pada saat simulasi dijalankan. Penyulang Wastra Indah mengalami kenaikan beban puncak karena adanya manuver beban ke penyulang Wastra Indah yang disebabkan penyulang lain mengalami gangguan listrik atau ada pemeliharaan listrik.



Gambar 5. Hasil forecasting menggunakan metode Arima pada Penyulang Wastra Indah dengan proporsi data *training* 90% dan data *testing* 10%



Gambar 6. Hasil forecasting menggunakan metode *Deep Learning* pada Penyulang Wastra Indah dengan proporsi data *training* 90% dan data *testing* 10%

Hasil peramalan beban jangka pendek dalam bentuk kurva dapat dilihat pada Gambar 5 dan Gambar 6 secara berturut-turut untuk simulasi menggunakan metode ARIMA dan *Deep Learning* pada Penyulang Wastra Indah.

4. Kesimpulan

Berdasarkan analisis data hasil simulasi dapat disimpulkan bahwa kedua metode, yaitu metode *Deep Learning Long Short-Term Memory* dan metode ARIMA, dapat digunakan untuk peramalan beban jangka pendek sistem kelistrikan Kota Batu. Secara umum penggunaan metode *deep learning* memberikan hasil peramalan yang lebih baik daripada penggunaan metode ARIMA, kecuali jika terjadi anomali pembebanan yang mengakibatkan perubahan karakteristik data yang digunakan dalam simulasi.

Referensi

- [1]. Rehman A, Deyuan Z, Chandio A, Hussain I. An empirical analysis of rural and urban population' access to electricity: evidence from Pakistan. *Energy, Ssustainability and Society*. Vol. 8 no 1, 2018, p. 1-9
- [2]. Marsudi D. *Operasi Sistem Tenaga Listrik*. Edisi Pertama. Yogyakarta: Graha Ilmu. 2006: 24.
- [3]. Muzaffar S, Afshari A. Short-Term Load Forecast Using LSTM Network. *Energy Procedia*, Vol. 158, 2019, pp. 2922-2927.
- [4]. Yang T. *Electric Load Forecasting Using Long Short-term Memory Algorithm*. PhD Thesis. Virginia: Postgraduate Virginia commonwealth university: 2019.
- [5]. Zhu, G., Peng, S., Lao, Y., Su, Q. and Sun, Q., 2021. Short-Term Electricity Consumption Forecasting Based on the EMD-Fbprophet-LSTM Method. *Mathematical Problems in Engineering*, 2021. Article ID 6613604, 9 pages.
- [6]. Agung S, Budi S. Pembangunan Kota Wisata Batu Dalam Perspektif Sosial dan Ekonomi Masyarakat. *Jurnal REFORMASI UNITRI* Vol. 7 No. 1, 2017.
- [7]. Putra J W. *Pengenalan Konsep Pembelajaran Mesin dan Deep Learning*. Institut Teknologi Bandung. 2019.

- [8]. Kevin G. An introduction to neural networks. UCL Press Limited, 11 New Fetter Lane London. 1997.
- [9]. Shi D, Ping W, Khushnood A. A survey on deep learning and its applications, Computer Science Review, Volume 40, 2021, 100379, ISSN 1574-0137.
- [10]. Aulia K. Peramalan Beban Listrik Jangka Pendek Menggunakan Kombinasi Metode Autoregressive Integrated Moving Average (ARIMA) dengan Regresi Linear Antara Suhu dan Daya Listrik. Skripsi. Fakultas Teknik. Universitas Indonesia. Depok. 2011.
- [11]. Bagus D. Peramalan Beban Listrik Jangka Pendek Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditional Heteroskedacity (GARCH). Skripsi. Universitas Indonesia Jakarta. 2012.
- [12]. Hochreiter S, Schmidhuber J. Long short-Term Memory. Massachusetts Institute of Technology. 1997.
- [13]. Senen A, T. Ratnasari.. Studi Peramalan Beban Rata-Rata Jangka Pendek Menggunakan Metoda Autoregressive Integrated Moving Average (Arima. Jurnal Ilmiah SUTET, vol. 7 no. 2, 2017, pp.93-101.
- [14]. Kristiana, Ana, Yuciana Wilandari, and Alan Prahutama. "Peramalan Beban Puncak Pemakaian Listrik Di Area Semarang Dengan Metode Hybrid Arima (Autoregressive Integrated Moving Average)-anfis (Adaptive Neuro Fuzzy Inference System)(Studi Kasus Di PT Pln (Persero) Distribusi Jawa Tengah Dan DIY)." Jurnal Gaussian, vol. 4, no. 4, 2015, pp. 714-723.
- [15]. Noveri E. Studi Peramalan (Forecasting) Kurva Beban Harian Listrik Jangka Pendek Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA). Jurnal Nasional Teknik Elektro, 2(1), 2013, pp.65-73.