

Peramalan Daya Pembangkit Di PLTGU Gresik Berdasarkan Indeks Keandalan LOLP dan LOLE dengan Metode LSTM-NN

Dwikky Sucahyo Putra

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya

e-mail: dwikky.19008@mhs.unesa.ac.id

Unit Three Kartini

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya

e-mail: unitthree@unesa.ac.id

Abstrak

Peramalan daya pembangkit merupakan proses memprediksi besaran daya yang akan dihasilkan oleh pembangkit listrik di masa yang akan datang. Peramalan daya pembangkit yang akurat sangat penting untuk mengoptimalkan operasi pembangkit listrik termasuk perencanaan produksi, perawatan dan perbaikan, pengaturan pengiriman daya, dan manajemen resiko. Namun seringkali terjadi hasil peramalan yang dilakukan memiliki tingkat keakuratan yang kurang. Oleh karena itu peneliti akan mencoba meramalkan daya pembangkit di PT. PLN Nusantara Power UP Gresik dengan tujuan agar mendapat hasil yang akurat. Metode yang akan digunakan adalah *Deep Learning Long Short Term Memory* (LSTM). Sementara untuk variabelnya adalah data historis daya, indeks keandalan *Loss of Load Probability* (LOLP), serta indeks keandalan *Loss of Load Expectation* (LOLE). Pada penelitian ini, peramalan yang dilakukan menghasilkan prediksi daya pembangkit untuk jangka waktu 6 jam kedepan. Hasil dari peramalan daya tersebut menghasilkan nilai MAE sebesar 0,0128 dan MSE sebesar 0,0004. Hal itu menunjukkan bahwa nilai Indeks Keandalan LOLP dan LOLE dapat digunakan sebagai input variabel bersama dengan data historis daya dalam meramalkan besarnya daya suatu pembangkit.

Kata Kunci: LSTM, *Deep Learning*, *Forecasting*, Pembangkit Listrik

Abstract

Generating power forecasting is the process of predicting the amount of power that will be generated by a power plant in the future. Accurate generation power forecasting is essential for optimizing power plant operations including production planning, maintenance and repair, power delivery arrangements, and risk management. However, it often happens that the results of forecasting that are carried out have a less level of accuracy. Therefore researchers will try to predict the generating power at PT. PLN Nusantara Power UP Gresik with the aim of getting accurate results. The method to be used is *Deep Learning Long Short Term Memory* (LSTM). Meanwhile, the variables are power historical data, *Loss of Load Probability* (LOLP) reliability index, and *Loss of Load Expectation* (LOLE) reliability index. In this study, the predictions made generate predictions of generating power for the next 6 hours. The results of the power forecasting produce an MAE value of 0.0128 and an MSE of 0.0004. This shows that the LOLP and LOLE Reliability Index values can be used as input variables together with power historical data in predicting the amount of power of a generator.

Keywords: LSTM, *Deep Learning*, *Forecasting*, Power Plants

PENDAHULUAN

Latar Belakang

Kebutuhan akan tenaga listrik di Indonesia khususnya di Jawa Timur terus meningkat dari waktu ke waktu sejalan dengan meningkatnya kegiatan ekonomi dan kesejahteraan masyarakat. Dampaknya adalah semua komponen tenaga listrik akan mengalami pengurangan keandalan (Suripto, 2016). Hal tersebut tentu saja harus diantisipasi dengan menyediakan sistem kelistrikan yang lebih memadai baik jumlah maupun kualitasnya di masa yang akan datang. Energi terbarukan merupakan solusi yang paling efektif dalam mengatasi permasalahan tersebut. Akan tetapi sistem tenaga listrik dengan energi terbarukan masih dalam tahap

pengembangan, dan untuk menjaga kualitas dan kuantitas sistem tenaga listrik saat ini maka dibutuhkan peramalan dan perencanaan yang tepat. Sebuah peramalan akan melibatkan pengambilan data historis dan kemudian diproyeksikan ke masa yang akan datang dengan menggunakan model matematika (Tao dkk, 2019).

Peramalan meliputi diantaranya peramalan daya pembangkit dan peramalan jumlah konsumsi energi listrik. Peramalan daya sangat penting dilakukan untuk kegiatan ekonomi seperti pembangkitan energi, pembelian bahan bakar, pemeliharaan dan penjadwalan perawatan (Spyros dkk, 2020). Total daya yang dihasilkan oleh pembangkit harus menyesuaikan kebutuhan daya

yang ada pada konsumen (Chun – Hung, dkk. 2021). Apabila daya yang dikirim pembangkit lebih besar dari penggunaan konsumen maka menimbulkan pemborosan pembangkitan energi listrik, sebaliknya jika yang dibangkitkan dan dikirimkan lebih rendah atau maka kebutuhan konsumen tidak dapat terpenuhi (Mohammad, 2019).

Peramalan daya selalu menjadi bagian penting pada operasi sistem tenaga listrik mulai dari pembangkitan, analisa aliran daya, hingga produksi ekonomis sistem tenaga listrik (Meftah dan Merabet, 2022). Peramalan berdasarkan rentang waktu dapat dikategorikan menjadi peramalan jangka pendek, jangka menengah, dan jangka panjang (Lusiana dan Yularty, 2020).

Pada penelitian kali ini, yang akan menggunakan metode tunggal *Artificial Intelligence* (AI). AI merupakan teknologi era baru yang mempunyai kemampuan melakukan *forecasting* dengan metode *Deep Learning* (Scott, 2018). Deep structured learning atau yang biasa disebut dengan deep learning merupakan era baru dari machine learning (Taofeek dkk, 2020). Dalam *Deep Learning* sebuah komputer belajar mengklasifikasi secara langsung dari gambar, data ataupun suara. Banyaknya data yang diperoleh seiring dengan meningkatnya ketersediaan repository yang besar, dan dapat diaplikasikan dalam deep learning untuk menghasilkan proses grafik secara adaptif (Bacciu dkk, 2020). Dalam hal peramalan, metode salah satu metode *deep learning* yang bisa digunakan adalah metode *Long Short Term Memory* (LSTM) *neural network*, yaitu sistem saraf berulang yang kuat dan dirancang khusus untuk mengatasi masalah gradient melonjak ataupun hilang yang biasanya muncul saat mempelajari dependensi jangka panjang bahkan saat jeda waktu minimal sangat lama (Greg dkk, 2020). LSTM *neural network* adalah salah satu metode klasifikasi dinamis paling kuat yang digunakan saat ini (Ralf, 2019). LSTM dapat mengatasi masalah ketergantungan jangka panjang saat memprediksi data urutan jangka panjang dan memiliki keunggulan yang lebih kuat dalam pemodelan prediksi data waktu (Yutong dkk, 2022).

Data yang digunakan dalam penelitian kali ini adalah data daya pada periode sebelumnya dan indeks keandalan pembangkit berupa Loss of Load Probability (LOLP) dan Loss of Load Expectation (LOLE). LOLP adalah suatu kondisi dimana beban puncak melebihi kapasitas dari daya yang tersedia. Kinerja keandalan sistem pembangkit tenaga listrik dalam memenuhi kebutuhan beban direpresentasikan dengan LOLP (Shahril, 2022). Metode perhitungan indeks keandalan LOLP dapat digunakan untuk mengevaluasi keperluan dari cadangan daya yang diperlukan konsumen.

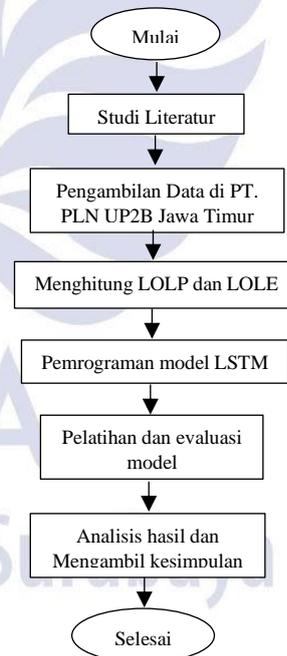
Sedangkan LOLE adalah kondisi beban puncak harian yang akan melebihi kapasitas dayanya. Pengertian lain dari LOLE adalah jumlah unit dalam satu waktu (jam atau hari) per interval waktu (tahun) yang permintaan bebannya melebihi kapasitas dayanya. Pemadaman kapasitas tertentu membantu sistem dengan jumlah pemadaman stokastik yang ada dan jumlah unit waktu. Periode perhitungan bisa dengan jangka waktu mingguan, bulanan, ataupun tahunan (Selahattin dkk, 2022).

Rumusan masalah pada penelitian ini secara umum adalah peramalan jangka sangat pendek yaitu 3 jam kedepan di PLTGU PT. PLN Nusantara Power UP Gresik menggunakan metode matematis yang sudah dikembangkan *Deep Learning* yaitu LSTM *neural network*. Perhitungan pada peramalan ini berdasarkan indeks keandalan dari pembangkit tersebut, yaitu LOLP dan LOLE.

METODE

Rancangan Penelitian

Pada penelitian ini pendekatan yang dilakukan adalah dengan metode penelitian secara eksperimen dimana pada praktiknya menggunakan pendekatan kuantitatif. Sementara itu untuk rancangan penelitian yang lebih jelas dapat dilihat pada Gambar 1.



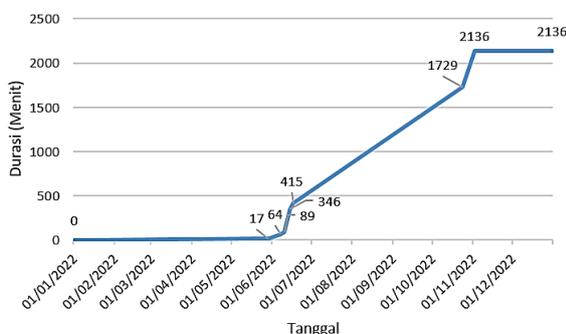
Gambar 1. Flowchart Rancangan Penelitian

Perhitungan LOLP

Data yang telah dikumpulkan peneliti adalah data daya pembangkit selama satu tahun terakhir dan data gangguan juga dalam kurun waktu satu tahun

Peramalan Daya Pembangkit Di PLTGU Gresik Berdasarkan Indeks Keandalan LOLP dan LOLE dengan Metode LSTM-NN

terakhir. Data daya pembangkit dapat langsung digunakan dalam proses peramalan, akan tetapi data gangguan harus diolah terlebih dahulu yaitu dengan menghitung nilai indeks keandalan LOLP dan LOLE pada pembangkit di PT. PLN Nusantara Power UP Gresik. Data gangguan yang terjadi dalam kurun waktu setahun terdapat pada Gambar 2 .



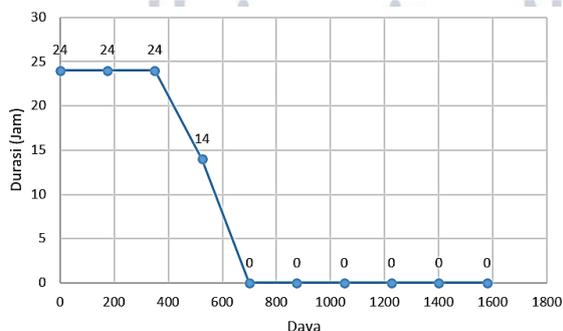
Gambar 2. Data Gangguan 2022
Sumber : (PT. PLN Persero, 2023)

Kemudian data tersebut kita masukkan ke dalam rumus untuk mencari nilai FOR. *Force Outage Rate* atau FOR merupakan tingkat kegagalan sistem pembangkit yang disebabkan oleh faktor – faktor eksternal. Rumus FOR dapat dilihat pada Persamaan 1.

$$FOR = \frac{DG}{JO + DG} \quad (1)$$

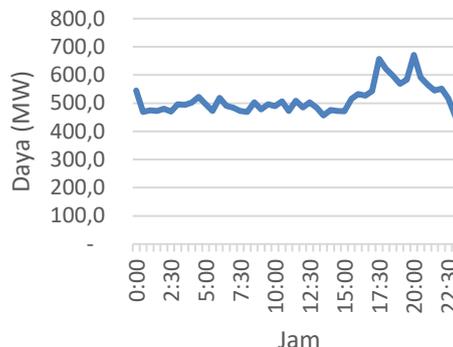
Keterangan : DG = Durasi Gangguan (Jam)
JO = Jam Operasi (Jam)

Dari rumus diatas, didapatkan hasil nilai FOR sebesar 0,6. Hasil perhitungan tersebut merupakan merupakan nilai FOR untuk 9 pembangkit di UP Gresik secara keseluruhan, sehingga untuk nilai FOR masing – masing pembangkit adalah 0,07. Selanjutnya kita dapat langsung memasukkan nilai tersebut dalam rumus mencari LOLP. Sebagai contoh kita akan menghitung nilai LOLP untuk tanggal 1 Januari 2022. Namun sebelumnya kita harus mengetahui bagaimana grafik daya pada pembangkit yang ditunjukkan pada Gambar 3.



Gambar 3. Grafik Daya 1 Januari 2022

Setelah itu kita petakkan grafik tersebut sesuai dengan jumlah pembangkit yang ada. Perlu diketahui bahwa PLTGU UP Gresik memiliki 9 unit pembangkit dengan total kapasitas mencapai 1578 MW. Pmetakkan daya pada Pembangkit dapat terlihat pada Gambar 4.



Gambar 4. Pemetakkan Data Daya Pembangkit

Setelah pemetakkan data daya pada pembangkit dilakukan, Selanjutnya kita bisa membuat tabel kembali untuk mempermudah perhitungan LOLP yang ditunjukkan pada Tabel 1.

Tabel 1. Perumusan LOLP

Daya Gangguan	Daya operasi	Individual	Kumulatif	Jam
0	1578	0,5204	1,0000	0
175	1400	0,0391	0,0423	0
350	1225	0,00295	0,00319	0
525	1050	0,000295	0,00319	0
700	875	0,0000167	0,0000181	0
875	700	0,00000126	0,00000143	0
1050	525	0,000000094	0,000000171	14
1225	350	0,000000071	0,000000077	24
1400	175	0,000000005	0,000000058	24
1578	0	0,0000000004	0,0000000004	24

Untuk perhitungan kemungkinan individual dan kemungkinan kumulatif pada tabel diatas, dapat menggunakan rumus yang ditunjukkan pada Persamaan 2.

$$KI = FOR^x * (1 - FOR)^y \quad (2)$$

Keterangan: KI = Kemungkinan Individual
FOR = *Force Outage Rate*
X = Jumlah pembangkit gangguan
Y = Jumlah pembangkit beroperasi

Sementara itu untuk kemungkinan kumulatif merupakan jumlah total dari Kemungkinan individual. Setelah mengetahui nilai kemungkinan individual dan kemungkinan kumulatif kita dapat menemukan nilai LOLP dengan mengkalikan kemungkinan kumulatif dengan durasi daya pembangkit seperti pada Tabel 2.

Tabel 2. Perhitungan LOLP

Kemungkinan Individual	Kemungkinan Kumulatif	Durasi (Jam)	LOLP
0,0391	0,0423	0	0
0,00295	0,00319	0	0
0,000295	0,00319	0	0
0,0000167	0,0000181	0	0
0,00000126	0,00000143	0	0
0,0000000946	0,000000171	14	0,000002394
0,0000000712	0,000000077	24	0,000001848
0,0000000054	0,0000000058	24	0,000000139
0,0000000004	0,0000000004	24	0,000000009

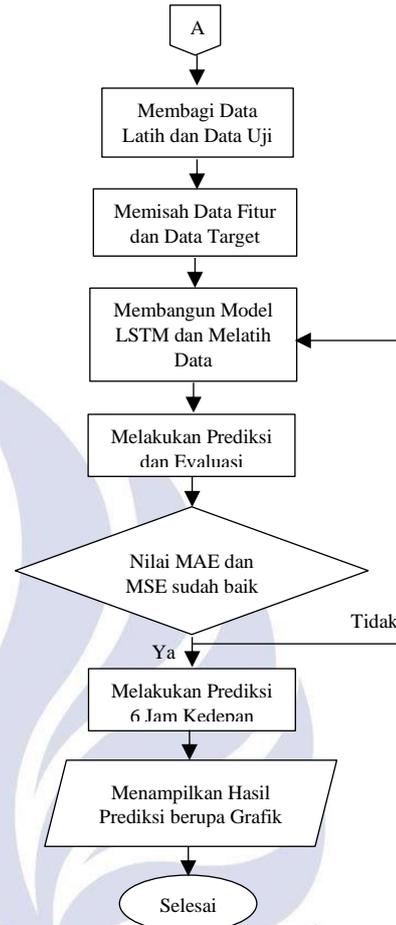
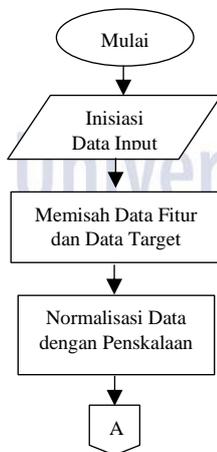
Berdasarkan tabel diatas, maka nilai indeks keandalan LOLP pada tanggal 1 Januari 2022 adalah 0,00000439 jam per hari. Angka tersebut dapat dikategorikan nilai yang cukup baik untuk sebuah pembangkit tenaga uap yang mapu memproduksi daya sekitar 1500 MW.

Perhitungan LOLE

Setelah mengetahui nilai LOLP, selanjutnya kita dapat mencari nilai LOLE dari nilai tersebut. Karena LOLE yang kita gunakan adalah dalam jangka satu tahun, maka perhitungannya adalah nilai LOLP yang telah dihitung terlebih dahulu dikalikan 365 hari yang menghasilkan nilai 0,001602 jam per tahun. Nilai tersebut juga tergolong cukup baik, sehingga dapat dikatakan bahwa PLTGU UP Gresik memiliki nilai indeks keandalan yang baik. Hal ini selaras dengan hasil perhitungan LOLP yang ditunjukkan pada Tabel 2.

Pemodelan LSTM

LSTM *neural network* akan digunakan untuk membaca dari data – data yang sudah dikumpulkan menjadi sebuah ramalan beban pada pembangkit dengan jangka periode waktu tertentu. Untuk pemrograman dalam permodelan LSTM *neural network* ini dilaksanakan dengan menggunakan software Python. Skema pemrograman dapat dilihat pada Gambar 5.



Gambar 5. Flowchart Pemrograman

HASIL DAN PEMBAHASAN

Hasil yang didapatkan dalam proses yang dilakukan adalah hasil peramalan terhadap data uji, selain itu juga terdapat hasil peramalan untuk enam jam kedepan.

Peramalan Terhadap Data Uji

Dalam melakukan peramalan terhadap sebuah data, perlu adanya parameter yang sesuai dengan karakteristik data yang akan diprediksi. Dalam pemrograman LSTM terdapat beberapa parameter yang dapat kita sesuaikan diantaranya adalah *Time Steps*, *Epoch*, dan *Batch*.

Time Steps merupakan interval waktu antara dua titik yang berurutan dalam sebuah data, bisa dalam bentuk harian, mingguan, atau bahkan bulanan. Fungsinya adalah membantu menganalisa pola dan tren dalam sebuah data. *Epoch* merupakan satu iterasi lengkap yang melalui seluruh set data pelatihan. Saat satu *epoch* berlangsung, model mengalami pembaruan berulang berdasarkan data pelatihan untuk meningkatkan performanya.

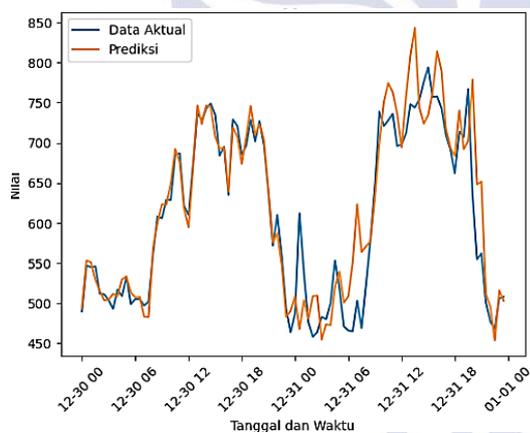
Batch merupakan jumlah sampel data yang digunakan untuk menghitung dan memperbarui gradien dalam satu iterasi. Ukuran *batch*

berpengaruh terhadap kecepatan pelatihan model, penggunaan memori, serta performa dan generasi model. Hasil peramalan dengan parameter ketiga hal tersebut dapat dilihat pada Tabel 3.

Tabel 3. Percobaan dengan Parameter *Time Steps*, *Batch*, dan *Epoch*

No.	Time Steps	Epoch	Batch	MAE	MSE
1.	10	50	32	0,0328	0,0021
2.	24	50	32	0,0312	0,0019
3.	48	50	32	0,0305	0,0017
4.	48	25	32	0,0311	0,0018
5.	48	50	32	0,0305	0,0017
6.	48	100	32	0,0279	0,0014
7.	48	100	32	0,0279	0,0014
8.	48	100	48	0,0194	0,0007
9.	48	100	96	0,0128	0,0004

Secara umum, seluruh percobaan yang telah dilakukan telah mendapatkan hasil yang cukup baik. Hal ini dapat dilihat dari angka MAE dan MSE yang relatif kecil bahkan dibawah 1 atau mendekati 0. Selain itu, hasil percobaan yang cukup baik juga dapat dilihat dari bentuk grafik yang dihasilkan memiliki besaran dan pola yang hampir mirip dengan data aktual. Dan untuk percobaan dengan hasil paling baik adalah percobaan dengan parameter *Time Steps* 48, *Epoch* 100, dan *Batch* 96.



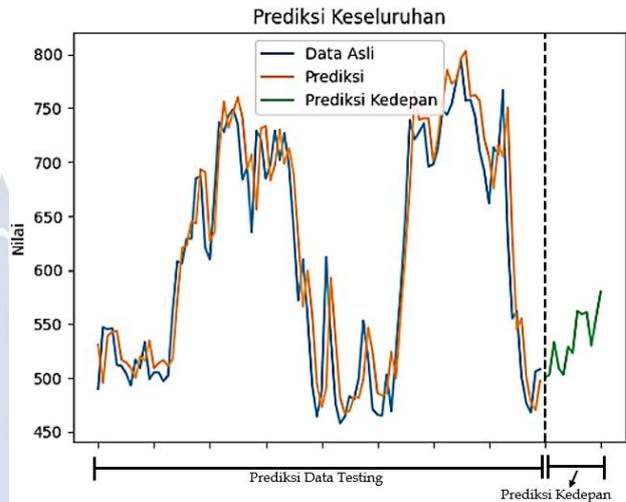
Gambar 6. Hasil Percobaan Terbaik

Hasil terbaik dari beberapa percobaan yang telah dilakukan ditunjukkan pada Gambar 6. Hal ini berdasarkan nilai MAE dan MSE yang sangat rendah atau bahkan mendekati 0, masing – masing yakni 0,0128 MW dan 0,0004 MW. Selain itu yang menjadi indikator hasil percobaan tersebut dikatakan baik adalah besaran nilai dan pola grafik yang mirip dengan data aktual yang ada.

Peramalan 6 Jam Kedepan

Setelah mendapatkan hasil percobaan yang baik dalam peramalan terhadap data uji, maka selanjutnya adalah meramalkan. untuk jangka waktu 6 jam kedepan. Peramalan akan dilakukan menggunakan model LSTM yang hampir sama halnya

dengan yang digunakan dalam meramal data uji. Hal ini dikarenakan tingkat akurasi tinggi yang didapat sebelumnya, diharapkan bisa menghasilkan peramalan untuk 6 jam kedepan dengan performa yang baik dengan hasil seperti pada Gambar 7.



Gambar 7. Hasil Percobaan Keseluruhan

Peramalan dilakukan menggunakan model LSTM yang hampir sama halnya dengan yang digunakan dalam meramal data uji, hanya saja perlu sedikit penyesuaian karena bentuk inputan yang sedikit berbeda dengan sebelumnya. Dapat dilihat pada Gambar 7 bahwa prediksi besaran daya pembangkit PLTGU UP Gresik untuk 6 Jam kedepan relatif meningkat. Dari mulai pukul 00.00 sekitar 500 MW sampai dengan pukul 06.00 sekitar 580 MW.

PENUTUP

Simpulan

Berdasarkan hasil dari seluruh percobaan yang telah dilakukan dan juga analisis terkait hasil peramalan daya pembangkit menggunakan LSTM, dapat diambil kesimpulan bahwa indeks keandalan LOLP dan LOLE cukup mempengaruhi hasil peramalan terhadap daya pembangkit. Hal itu dapat dilihat dari hasil peramalan yang dilakukan yang memiliki tingkat akurasi yang sangat baik ketika LOLE dan LOLP digunakan sebagai input variabel bersama dengan data historis daya periode sebelumnya. Selain itu penyesuaian parameter dalam pemodelan LSTM seperti *Time Steps*, *Epoch*, dan *Batch* juga cukup berpengaruh dalam menghasilkan nilai peramalan. Sementara itu hasil peramalan terbaik pada penelitian ini adalah dengan menggunakan paramter *Time Steps* = 48, *Epoch* = 100, dan *Batch* = 96 dan menghasilkan tingkat keakuratan dengan nilai MAE = 0,0128 dan MSE = 0,0004. Sedangkan untuk prediksi dalam kurun waktu 6 jam kedepan dihasilkan grafik yang relatif meningkat. Dimulai dari pukul 00.00 dengan 500 MW, hingga pukul 06.00 dengan daya sekitar 580 MW.

Saran

Dalam melakukan peramalan menggunakan model LSTM, peneliti menyarankan agar menggunakan data inputan yang cukup banyak. Karena sesuai dengan hasil penelitian yang dilakukan, semakin banyak data yang digunakan maka semakin bagus tingkat keakuratan yang dihasilkan. Selain itu, peneliti juga menyarankan agar pada hendak melakukan peramalan sebaiknya kita memahami sedikit banyak tentang karakteristik data yang kita miliki dan nantinya akan kita gunakan sebagai inputan. Beberapa hal yang perlu diperhatikan adalah seperti interval waktu, tren, dan juga pola data.

DAFTAR PUSTAKA

- Bacciu. Davide, dkk. 2020. *A Gentle Introduction to Deep Learning for Graphs*. University of Pisa, Italy.
- Chun – Hung. Liu, JYH – Cheng Gu, dan Ming – Ta Yang. 2021. *A Simplified LSTM Neural Network for One Day – Ahead Solar Power Forecasting*. IEEE Access, Vol 9 pp Hal 17174 – 17195.
- Greg. Van Houdt, Carlos Mosquera dan Gonzalo Napoles. A 2020. *Review on The Long Short-Term Memory Model*. Artificial Intelligence Review 53, 5929-5955.
- Lusiana. Anna dan Yuliaty. Poppy. 2020. *Penerapan Metode Peramalan (Forecasting) pada Permintaan Atap di PT X*. Jurnal Teknik Industri E-ISSN 2615 – 3866. ITN Malang.
- Meftah. Elsaraiti dan Merabet Abel. 2022. *Solar Power Forecasting Using Deep Learning Techniques*. IEEE Access Vol 10 pp 31692-31698. Saint Mary's University Halifax, Canada.
- Mohammad H. Ahmadi, dkk. 2018. *Thermodynamic and Economic Analysis of Performance Evaluation of All Thermal Power Plants: A Review*. Journal Science and Engineering, Vol 7 (1), Hal 30 – 65.
- Ralf C. Staudemeyer dan Eric Rothstein Morris. 2019. *–Understanding LSTM- A Tutorial Into Long Short-Term Memory Reccurent Neural Networks*. arXiv.
- Scott. 2018. *Deep Learning for Dummies*. John Wiley & Sons, Inc.
- Selahattin. Garip, Saban. Ozdemir dan Necmi. Altin. 2022. *Power System Reability Assessment – A Review on Analys and Evaluation Methods*. Journal of Energy Systems, Vol 6 No. 3 2602-2052. Gazi University, Turkiye.
- Shahril. I Sulaiman, Hamizah AB Majid dan Zulkifli Othman. 2022. *Loss of Load Probability Minimization for Stand-alone Photovoltaic System Using Elephant Herding Optimization*. Energy Reports 8 1038-1044. Universiti Teknologi MARA, Malaysia.
- Spyros. Makridakis, dkk. 2020. *Forecasting in Social Settings : The State of Art*. International Journal of Forecasting 36 Hal 15 -28. Monash University, Australia.
- Suripto. Slamet. 2016. *Sistem Tenaga Listrik*. Teknik Elektro-UMY.
- Tao. Hong, dkk. 2020. *Energy Forecasting : A Review and Outlook*. IEEE Journal of Power and Eenergy. Vol 7, 376-388.
- Taofeek. D. Akinosho, dkk. 2020. *Deep Learning in The Contruction Industry : A Review of Present Status and Future Innovations*. Journal of Building Engineering 32 – 101827. Brunel University London, United Kingdom.
- Yutong. He, dkk. 2022. *Short-term Photovoltaic Power Forecasting Method Based On Convolutional Neural Network*. Journal of Energy Reports. Vol 8, Hal 54-62. EIEIT 2022, Wuhan, China.