

PERAMALAN JANGKA PENDEK HASIL PRODUKSI DAYA PLTS 7MWp DENGAN METODE *LONG SHORT-TERM MEMORY (LSTM)*

Zamzami Ahmad¹, I Made Budi Suksmadana²

zamzamiahmad010302@gmail.com¹, [mdbudisuk@unram.ac.id](mailto: mdbudisuk@unram.ac.id)²

Universitas Mataram

Abstrak

Sumber energi terbarukan dimasa mendatang akan semakin mempunyai peran yang sangat penting dalam memenuhi kebutuhan energi. Saat ini pemanfaatan energi terbarukan renewable energy sedang digalakkan untuk dapat mengurangi pemakaian energi tidak terbarukan. Pembangkit listrik fotovoltaik (PV) menjadi salah satu solusi untuk mengatasi kelangkaan energi. PLTS Pringgabaya dengan kapasitas 7MWp adalah salah satu implementasi dari pemanfaatan renewable energy. Penelitian ini bertujuan untuk meramalkan hasil produksi daya jangka pendek PLTS Pringgabaya menggunakan metode Long Short-Term Memory (LSTM). Prediksi jangka pendek ini penting dikarenakan variabilitas produksi daya yang disebabkan berbagai faktor yang dapat mempengaruhi pengelolaan energi dan integrasi ke jaringan listrik. Data historis hasil produksi daya satu bulan dari tanggal 1 Juni hingga 30 Juni digunakan sebagai input model. Dua skenario pengujian dilakukan, yaitu dengan epoch 500 dan epoch 1000. Hasil menunjukkan bahwa mode dengan epoch 1000 memiliki nilai Mean Squared Error (MSE) sebesar 0.003, lebih rendah dibanding dengan skenario menggunakan epoch 500 yang memiliki MSE 0.004. Dapat disimpulkan bahwa semakin kecil nilai MSE, maka hasil peramalan semakin bagus dan metode LSTM memiliki interpretasi peramalan dengan predikat layak.

Kata Kunci: Renewable Energy, Forecasting, Neural Network.

1. PENDAHULUAN

Energi merupakan salah satu kebutuhan dasar bagi pembangunan ekonomi dan sosial suatu negara. Peningkatan kebutuhan energi seiring dengan pertumbuhan populasi dan industrialisasi menuntut adanya diversifikasi sumber energi untuk menjamin ketersediaan energi yang berkelanjutan. Dalam beberapa dekade terakhir, perhatian global telah beralih ke sumber energi terbarukan yang lebih ramah lingkungan. Pembangkit Listrik Tenaga Surya (PLTS) adalah salah satu teknologi energi terbarukan yang mengalami perkembangan pesat karena potensinya yang besar dan dampak lingkungan yang minimal.

PLTS Pringgabaya dengan kapasitas 7 Megawatt peak (MWp) adalah salah satu proyek penting dalam upaya mengadopsi energi terbarukan. Namun, salah satu tantangan utama dalam operasional PLTS adalah variabilitas produksi daya yang

disebabkan oleh perubahan kondisi cuaca. Variabilitas ini menyulitkan pengelolaan energi dan integrasi ke dalam jaringan listrik.

Peramalan produksi daya jangka pendek menjadi penting dalam mengatasi tantangan ini, sehingga operator dapat mengelola produksi daya dengan lebih baik dan mengantisipasi fluktuasi produksi. Saat ini, metode berbasis machine learning, khususnya Long Short-Term Memory (LSTM), telah menunjukkan hasil yang menjanjikan dalam peramalan data deret waktu, termasuk produksi daya listrik dari PLTS (Purwantoro et al., 2022). LSTM, yang merupakan varian dari Recurrent Neural Network (RNN), memiliki kemampuan untuk mengatasi masalah vanishing gradient dan dapat belajar dari data historis untuk menangkap pola jangka panjang dan jangka

pendek yang memengaruhi produksi daya (Dhaked & Dadhich, 2023).

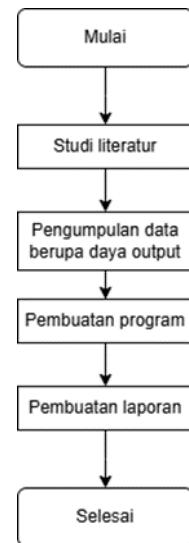
Beberapa penelitian telah membuktikan bahwa LSTM efektif dalam menghasilkan prediksi daya listrik dengan tingkat akurasi yang tinggi dibandingkan metode lainnya, seperti model Feed Forward Neural Network dan regresi linier (Purwantoro et al., 2022; Faiq & Tan, 2022). Metode ini mampu memanfaatkan data historis, sehingga model dapat mengidentifikasi pola fluktuasi daya secara lebih tepat (Khoirul & Kartini, 2023). Namun, penelitian mengenai implementasi LSTM untuk peramalan jangka pendek di PLTS dengan skenario pengujian yang berbeda masih relatif terbatas, terutama pada PLTS di kawasan tropis seperti Indonesia.

Penggunaan teknologi pembelajaran mesin, khususnya Long Short-Term Memory (LSTM), dalam prediksi produksi daya telah menunjukkan hasil yang menjanjikan. LSTM adalah jenis Recurrent Neural Network (RNN) yang efektif dalam menangani data deret waktu dan mampu mempelajari ketergantungan jangka panjang. Dengan demikian, penelitian ini bertujuan untuk mengembangkan model prediksi jangka pendek hasil produksi daya PLTS Pringgabaya menggunakan LSTM.

2. METODE PENELITIAN

tahapan yang dapat dilihat pada gambar 1.

1. Melakukan studi literatur yaitu membaca referensi.
2. Mengumpulkan data daya output yaitu Active Energy Export (KWh) dari tanggal 1 hingga 30 Juni.
3. Membuat program dengan Bahasa python di Google Collaboratory.
4. Pembuatan laporan.



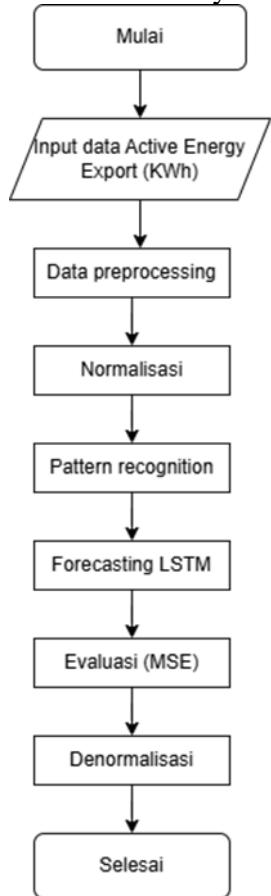
Gambar 1 alur penelitian

Flowchart alur kerja program

Perancangan flowchart alur kerja program agar proses kerja lebih sistematis sehingga memudahkan dalam peramalan daya. Langkah-langkah alur kerja program dapat dilihat pada flowchart di gambar 2

1. Memasukkan daya yang akan digunakan yaitu saya outpu satu bulan di dari tanggal 1 Juni hingga 30 Juni.
2. Melakukan pre-processing data, yaitu mengubah tipe data menjadi float dan mengatur variabel waktu (tanggalan) agar tidak
3. Normalisasi, yaitu mengubah skala data menjadi nilai 0 hingga 1 untuk membuat pengenalan pola jadi lebih baik. Metode normalisasi yang digunakan yaitu Min Max Scaler.
4. Pattern recognition, yaitu metode untuk memperbanyak data input dengan cara dengan cara membuat pola time series pada data.
5. Forecasting LSTM, ialah peramalan menggunakan algoritma Long Short-Term Memory.
6. Evaluasi adalah cara untuk mengetahui seberapa bagus model melakukan peramalan menggunakan MSE (Mean Squared Error).

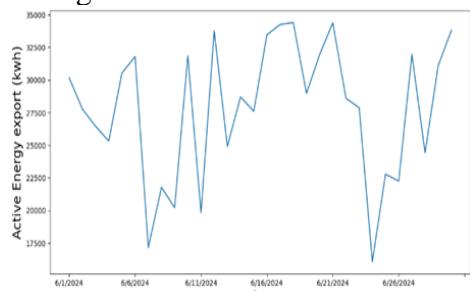
7. Denormalisasi, yaitu mengubah skala nilai hasil peramalan yang tadinya 0 hingga 1 menjadi skala nilai sebenarnya.



8. HASIL DAN PEMBAHASAN

Analisa data historis

Langkah pertama yang dilakukan adalah mengetahui data historis untuk melakukan prediksi. Data historis adalah data sebenarnya yang direkam oleh system monitoring scada



Gambar 1 Grafik data historis bulan juni

Dapat dilihat dari gambar 1 bahwa data historis sangat variatif dengan rentang nilai

16000 hingga 35000. Perubahan setiap harinya juga cukup signifikan sehingga cukup sulit untuk dikelola oleh program. Oleh karena itu dibutuhkan normalisasi mengubah skala fitur atau data sehingga berada dalam rentang yang lebih mudah dikelola dan konsisten.

Tabel 1 Data asli dan hasil normalisasi

Date	Data asli	Hasil normalisasi
01/06/2024	30153.751	0.76820639
02/06/2024	27774.665	0.6384488
03/06/2024	26444.389	0.56589429
04/06/2024	25318.475	0.50448588
05/06/2024	30527.189	0.78857405
06/06/2024	31790.807	0.85749297
07/06/2024	17158.116	0.05941221
08/06/2024	21765.421	0.31069897
09/06/2024	20209.157	0.22581886
10/06/2024	31848.281	0.86062766
11/06/2024	19816.339	0.2043942
12/06/2024	33771.833	0.96554
13/06/2024	24899.853	0.48165385
14/06/2024	28701.322	0.68898955
15/06/2024	27599.458	0.62889285
16/06/2024	33460.04	0.94853451
17/06/2024	34244.387	0.99131354
18/06/2024	34403.652	1
19/06/2024	28973.434	0.70383079
20/06/2024	31941.78	0.86572718
21/06/2024	34376.822	0.99853667
22/06/2024	28591.817	0.68301704
23/06/2024	27869.733	0.6436339
24/06/2024	16068.802	0
25/06/2024	22773.462	0.36567848
26/06/2024	22249.41	0.33709619
27/06/2024	31951.288	0.86624576
28/06/2024	24430.82	0.45607234
29/06/2024	31104.627	0.82006807
30/06/2024	33814.138	0.96784735

Tabel 1 adalah tabel data historis asli dan hasil normalisasi. Dapat dilihat pada data asli bahwa datanya sangat variatif dan perbedaannya juga cukup signifikan setiap harinya, hal ini cukup sulit untuk dikenali polanya. Oleh karena itu data tersebut

dinormalisasi untuk membuatnya berada dalam skala yang mudah dikenali yaitu diantara 0 hingga 1 untuk memudahkan pengenalan pola

Arsitektur model LSTM

Tabel 2 Parameter LSTM

Parameter	Keterangan
Layer	4
Fitur	1
Optimizer	Adam
Loss Function	MSE
Timestep	10
Epoch	500, 1000
Batch size	1

Berdasarkan tabel 2, skenario peramalan akan dibagi menjadi 2, yaitu dengan epoch 500 dan epoch 1000

Analisa hasil prediksi skenario 1 dengan epoch 500



Gambar 2 Hasil prediksi skenario 1

Pada skenario 1 yaitu dengan menggunakan Epoch = 500 yang artinya data akan dilatih sebanyak 500 kali untuk melakukan prediksi. Berdasarkan gambar 4.3 dapat kita ketahui hasil prediksi dari tanggal 1 Juli 2024 hingga 15 Juli 2024 dengan nilai yang variatif antara 20000 kWh untuk yang terendah dan 37000 kWh untuk nilai hasil produksi tertinggi. Secara umum sudah menghasilkan hasil prediksi dengan baik yang dapat dilihat dengan nilai Loss function

yang digunakan yaitu MSE dengan nilai yang kecil sebesar 0.0041.

Analisa hasil prediksi skenario 2 dengan epoch 1000



Gambar 3 Hasil prediksi skenario 2

Skenario ke-2 dilakukan menggunakan Epoch = 1000 yang artinya program akan melatih data sebanyak 1000 kali untuk melakukan prediksi.

Berdasarkan gambar 3 dapat kita ketahui hasil prediksi dari tanggal 1 Juli 2024 hingga 15 Juli 2024 dengan nilai yang variatif antara 15000 kWh untuk yang terendah dan 36000 kWh untuk nilai hasil produksi tertinggi. Secara umum sudah menghasilkan hasil prediksi dengan baik yang dapat dilihat dengan nilai Loss function yang digunakan yaitu MSE dengan nilai yang kecil sebesar 0.0030.

Hasil prediksi kedua skenario

Tabel 3 Hasil prediksi kedua skenario

Date	Skenario 1 (kWh)	Skenario 2 (kWh)
01/07/2024	27339.195	27500.887
02/07/2024	30807.936	30929.678
03/07/2024	33533.918	34450.523
04/07/2024	36987.723	36469.195
05/07/2024	28453.77	33959.918
06/07/2024	33038.613	32148.318
07/07/2024	20009.314	29195
08/07/2024	19689.87	28364.729
09/07/2024	21348.916	15132.792
10/07/2024	25221.217	19288.1
11/07/2024	26528.406	22600.32

12/07/2024	28903.9	33049.625
13/07/2024	26363.115	23513.979
14/07/2024	28211.12	33539.684
15/07/2024	28172.709	25283.965
MSE	0.004	0.003

Setelah mengetahui nilai hasil prediksi masing-masing skenario, pada tabel 3 adalah nilai perbandingan prediksi kedua skenario. Skenario 1 memiliki nilai loss function 0.0041, sedangkan skenario 2 memiliki nilai loss function 0.0030. Pada tabel dapat diketahui bahwa perbedaan hasil prediksi pada tanggal pada tanggal 1 – 4 Juni tidak berbeda jauh, sedangkan untuk tanggal 5 juni terlihat perbedaan yang cukup signifikan. Hal ini disebabkan oleh berbagai aspek seperti jumlah epoch yang digunakan pada pengujian, variasi dan jumlah data juga berpengaruh.

4. KESIMPULAN

1. Pada skenario 1 dengan epoch = 500 didapatkan nilai loss function sebesar 0.0041, untuk skenario 2 dengan epoch 1000 didapatkan nilai loss function 0.0030. Semakin kecil nilai loss function, maka semakin bagus hasil prediksi. Hal ini menandakan bahwa hasil peramalan menggunakan skenario 2 lebih baik dari skenario 1.
2. Metode Deep Learning-LSTM dapat digunakan sebagai sebuah metode untuk melakukan prediksi jangka pendek hasil produksi daya PLTS efektif dengan tingkat akurasi peramalan yang terbaik di dapatkan yaitu dengan nilai MSE 0.004 untuk skenario 1 dan 0.003 untuk skenario 2. Dengan demikian model ini dapat membantu memprediksi hasil produksi daya berdasarkan data historis hasil produksi daya sebelumnya.
3. Variabel data sangat berpengaruh dalam melakukan prediksi menggunakan metode deep learning LSTM karena dapat

menentukan seberapa baik model mempelajari dan memahami pola yang mendasari dalam data untuk membuat prediksi yang akurat.

5. DAFTAR PUSTAKA

- Khoirul, F., & Kartini, U. T. (2023). Peramalan Daya Listrik Jangka Sangat Pendek pada Pembangkit Fotovoltaik (PV) Menggunakan Metode Deep Learning Long Short-Term Memory.. Jurnal Teknik Elektro Volume 12 Nomor 1 Tahun 2023, 54-56.
- Kinasti, R.M.A, dkk. 2019." Sosialisasi dan Instalasi Panel Surya Sebagai Energi Terbarukan Menuju Kesadaran Lingkungan Indonesia Bebas Emisi. Jurnal Pengabdian Pada Masyarakat Menerangi Negeri. Vol. 2, No. 1, Desember 2019.
- Dhaked, D. K., & Dadhich, S. (2023). Power Output Forecasting of Solar Photovoltaic Plant using LSTM. Green Energy and Transportation Journal, 2(5).
- Purwantoro, K. E., Kartini, U. T., Suprianto, B. S., & Agung, A. I. (2022). Prediksi Daya Listrik Jangka Sangat Pendek Pembangkit Photovoltaic Berbasis Internet of Things Menggunakan Feed Forward Neural Network. Jurnal Teknik Elektro, 11(3), 286-396..
- Susanto, Y., & Raharjo, M. (2022). Penerapan Metode LSTM dalam Peramalan Daya Listrik PLTS Terhubung Jaringan. Jurnal Energi Baru Terbarukan Indonesia, 17(3), 101-109.
- Irawan, A. F., & Lestari, D. (2021). Prediksi Output Daya PLTS Berbasis Algoritma Long Short-Term Memory (LSTM). Jurnal Teknik Elektro Universitas Mercu Buana, 12(4), 123-130.
- Setiawan, B., & Suryadi, D. (2022). Implementasi LSTM untuk Prediksi Produksi Energi pada PLTS Skala Kecil. Jurnal Teknologi Terapan Energi Baru dan Terbarukan, 13(1), 67-73.
- Energy Vena. 2018. Pembangkit Listrik Tenaga Surya(PLTS),2018. Diakses tanggal 14 Oktober 2024.
- Jain, A., & Tripathi, S. (2022). Forecasting Solar PV Power Generation Using LSTM Networks. International Journal of

- Renewable Energy Research, 12(4), 203-214.
- Zhang, Z., et al. (2020). Comparative Study of LSTM and Other Deep Learning Models for Solar Power Prediction. Energy Reports, 6, 934-944.