

Prediksi Radiasi Surya Menggunakan Metode *Long Short-Term Memory*

Muhammad Rezza^{1,*}, M. Ismail Yusuf², Redi Ratiandi Yacoub³

Magister Teknik Elektro, Fakultas Teknik, Universitas Tanjungpura, Indonesia

¹mrezza91@gmail.com, ^{2,3}elektro@teknik.untan.ac.id

* penulis korespondensi

INFO ARTIKEL

Sejarah Artikel

Diterima: 10 Oktober 2023

Direvisi: 12 Februari 2024

Diterbitkan: 30 April 2024

Kata Kunci

LSTM

MSE

Prediksi Model

ABSTRAK

Penelitian ini memfokuskan pada optimalisasi pemanfaatan energi matahari di Kalimantan Barat, sebuah wilayah yang kaya akan sumber daya matahari, dengan total pembangkit listrik tenaga surya (PLTS) mencapai 1.58 MW. Untuk memprediksi potensi energi matahari, penelitian menggunakan metode jaringan syaraf tiruan *Long Short-Term Memory* (LSTM) dengan data yang diperoleh dari data logger yang merekam tegangan, arus, dan daya keluaran panel surya selama 57 hari dengan interval 1-2 detik, menghasilkan 4.294.273 data. Dalam pengolahan data, 80% digunakan untuk pelatihan dan sisanya untuk pengujian model LSTM. Model LSTM yang digunakan terdiri dari 2 layer LSTM, masing-masing dengan 50 node LSTM. Penggunaan Google Colaboratory sebagai platform komputasi memungkinkan pelatihan model LSTM dalam dua skenario, yaitu dengan epoch sebesar 1 dan 10. Evaluasi model dilakukan menggunakan metrik *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *R-squared* (R²). Hasil pengujian menunjukkan bahwa model dengan epoch 10 memiliki nilai evaluasi yang lebih baik, dengan MSE sebesar 0.04444, RMSE sebesar 0.00456, MAE sebesar 0.06753, dan R² sebesar 0.99961, menunjukkan performa prediksi energi matahari yang sangat akurat dan efisien.

PENDAHULUAN

Indonesia, yang terletak di sepanjang garis khatulistiwa, memperoleh sekitar 12 jam sinar matahari setiap harinya berkat lokasinya yang tropis. Kekayaan sinar matahari ini memberikan peluang besar dalam bidang energi surya. Berbeda dengan bahan bakar fosil, energi surya yang berasal dari radiasi matahari menawarkan solusi ramah lingkungan yang bebas dari polusi yang merusak ekosistem kita. Meskipun memiliki potensi besar, pada tahun 2020, energi surya hanya menyumbang 0,2% dari total produksi listrik Indonesia sebesar 72.750,72 MW, menurut Statistik Kelistrikan 2020 Kementerian Energi dan Sumber Daya Mineral. Meskipun demikian, terdapat tren positif dalam instalasi Pembangkit Listrik Tenaga Surya (PLTS), seperti yang terlihat di Kalimantan Barat, di mana telah dihasilkan energi sebesar 1,58 MW. Meskipun masih dalam skala yang terbatas, perkembangan ini menandakan langkah positif menuju pemanfaatan energi terbarukan dan bersih di Indonesia [1].

Inti dari pembangkitan energi surya adalah panel surya, yang kini semakin mudah diakses oleh masyarakat, didorong oleh keberadaan platform *e-commerce*. Panel-panel ini tidak hanya tersedia secara komersial; individu pun dapat membuat instalasi surya skala kecil untuk keperluan rumah tangga [2]. Memantau hasil produksi panel-panel ini sangat penting untuk menilai efisiensinya. Sistem pemantauan real-time tidak hanya memberikan


wawasan tentang kinerja saat ini, tetapi juga memprediksi produksi energi dalam jangka panjang, dengan mempertimbangkan berbagai faktor seperti suhu, kondisi cuaca, dan intensitas sinar matahari [3]. Prediksi cuaca, yang disebarluaskan melalui saluran media atau lembaga meteorologi, memberikan wawasan tentang kondisi cuaca mendatang. Namun, prediksi ini tidak secara langsung dapat diubah menjadi perkiraan energi yang akan dihasilkan oleh panel surya. Tantangannya terletak pada kemampuan memperkirakan produksi energi berdasarkan ramalan cuaca. Penelitian ini bertujuan untuk mengatasi kesenjangan ini dengan menggunakan sensor dan mikrokontroler untuk memantau produksi panel surya, menyimpan data ini untuk analisis lebih lanjut [4]. Teknologi kecerdasan buatan (AI) akan dimanfaatkan untuk memprediksi produksi energi surya, memberikan informasi berharga untuk mengoptimalkan sistem energi surya.

Dalam beberapa penelitian terkini mengenai prediksi daya panel surya, berbagai metode dan teknologi telah digunakan untuk meningkatkan akurasi prediksi. Mukromin menggunakan model regresi linear majemuk untuk memprediksi daya panel surya berdasarkan iradiasi surya, temperatur, dan output panel surya selama 2 hari [5]. Mereka memperoleh Mean Square Error sebesar 9.83, menunjukkan tingkat akurasi prediksi mereka. Priatama menggunakan mikrokontroler Arduino untuk merekam data arus dan tegangan dari panel surya. Hasilnya menunjukkan bahwa data dari mikrokontroler lebih akurat dibandingkan dengan pengukuran multimeter [6]. Erwanto menggunakan sensor INA219 untuk merekam data arus dan tegangan dari rangkaian panel surya yang dirancang untuk menyimpan data hasil perhitungan menggunakan Arduino [7]. Selain itu, penelitian oleh Cynthia menggunakan data dari BMKG untuk prediksi radiasi matahari dengan menggunakan *Elman Recurrent Neural Network*. Mereka mengubah skema pelatihan dan pengujian dengan variasi perbandingan data latih dan uji, dan mencapai akurasi tertinggi sebesar 96.531% dengan perbandingan 90:10 [8]. Penelitian lain oleh Khafaf menggunakan metode *Long Short-Term Memory* (LSTM) untuk prediksi jangka pendek dengan data energi dari perusahaan distribusi listrik setempat. Hasilnya menunjukkan bahwa LSTM merupakan metode yang efektif dengan Root Mean Square Error terbaik sebesar 3.61% [9]. Studi-studi ini menyoroti keberagaman metode dan teknologi yang digunakan dalam penelitian prediksi energi surya, membawa kontribusi penting untuk pengembangan teknologi energi terbarukan di masa depan.


Model prediktif yang digunakan dalam penelitian ini berkaitan dengan jaringan *Long Short-Term Memory* (LSTM), teknik deep learning yang sangat cocok untuk menganalisis data time-series yang kompleks dan tidak stabil [10]. Kemampuan unik LSTM terletak pada kemampuannya untuk menangkap pola jangka panjang dalam data time series, mengatasi tantangan yang dihadapi oleh model jaringan saraf yang lebih sederhana. Namun, teknik ini tidak tanpa kompleksitas; seringkali membutuhkan data yang substansial dan rentan terhadap overfitting - suatu kondisi di mana model terlalu beradaptasi dengan data pelatihan, menghambat kemampuannya dalam generalisasi pada data yang belum pernah dilihat sebelumnya [11].

METODE

Alat akuisisi data berjalan selama 24 jam nonstop selama 57 hari. Data direkam pada *memory card* dan sistem dilengkapi dengan manajemen pencatatan data saat listrik PLN mati dan hidup kembali secara otomatis. Model prediksi menggunakan LSTM dengan dua lapisan LSTM, masing-masing dengan 50 node. Data dibagi menjadi data pelatihan (80%) dan data uji (20%) [12]. Proses pelatihan dan pengujian model dilakukan menggunakan Google Colab, *platform berbasis cloud* yang menyediakan sumber daya komputasi, termasuk GPU sebagaimana disajikan pada Gambar 1.



Gambar 1. Pengkabelan Data Longger



Gambar 2. Model LSTM pada Pengujian

Pada tahap pengujian, model LSTM menggunakan metrik *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE) untuk mengevaluasi akurasi model. MSE digunakan untuk mengukur seberapa baik model memprediksi data, sedangkan RMSE memberikan informasi tentang error rata-rata dari prediksi model [13]. Semakin rendah nilai RMSE, semakin akurat model prediksi. Evaluasi model ini memberikan gambaran tentang seberapa baik model LSTM dapat memprediksi energi matahari berdasarkan data yang telah dikumpulkan sebagaimana ditunjukkan pada Gambar 2.


HASIL DAN PEMBAHASAN

Alat Pengukuran dan Pengujian Alat

Dalam penelitian ini, alat pengukuran terdiri dari Arduino, ethernet shield, dan komponen pendukung lainnya, yang disimpan dalam ruangan pada sudut ruangan tertentu. Panel surya dipasang di luar ruangan pada kanopi yang terpapar sinar matahari sepanjang hari, dengan ketinggian sekitar ± 5 meter di atas tanah dan kemiringan sekitar ± 5 derajat. Panel surya ini memiliki spesifikasi energi tertinggi sebesar 20W dengan jenis polycrystalline merek Mitsuyama. Kabel keluaran dari panel surya dihubungkan ke ground dan sensor INA219 yang merekam data pada data logger. Untuk memantau kinerja data logger, digunakan LCD display 16x2 pada Arduino. Setiap detik, tampilan display diperbarui untuk memperbaharui status data yang tersimpan pada memory card. Pengukuran dilakukan dengan interval 1 hingga 2 detik selama 24 jam setiap hari mulai dari tanggal 2 Maret 2023 hingga 28 April 2023. Pengukuran dan penyimpanan data dilakukan pada memory card dengan kapasitas 16GB tipe UHS-I Card merek Sandisk, yang kompatibel dengan mikrokontroler Arduino Mega melalui *ethernet shield*. Pengujian alat dilakukan untuk memastikan pembacaan sensor oleh mikrokontroler dan penyimpanan data pada SD memory card berjalan lancar. Alat ini menggunakan catu daya listrik dari PLN, sehingga saat terjadi pemadaman bergilir, mikrokontroler akan mati. Namun, saat listrik PLN menyala kembali, Arduino dan pencatatan waktu akan berjalan normal kembali secara otomatis tanpa perlu intervensi manusia. Hasil pengukuran yang berhasil disimpan pada *memory card* yang menunjukkan adanya keberhasilan akuisisi data dan penyimpanan data pengukuran.

Hasil dan Analisis Data

Dalam penelitian ini, data pengukuran energi dari panel surya dikumpulkan selama 57 hari, menghasilkan total 4.294.273 data energi. Rata-rata tertinggi energi yang dihasilkan setiap harinya adalah 13,438 Watt, dengan puncak tertinggi sebesar 15,4 Watt. Saat malam hari atau tidak ada sinar matahari, panel surya tidak menghasilkan energi. Data ini direpresentasikan dalam grafik pada Gambar 3, menunjukkan informasi power yang disimpan pada *memory card* melalui aplikasi Google Colab dengan menggunakan library Matplotlib.




Gambar 3. Grafik Hasil Data Pengukuran

Data tersebut juga dianalisis harian, dan pada hari ke-52, hanya 5,67 Watt energi yang dihasilkan karena kondisi cuaca hujan pada tanggal 23 April 2023. Rincian puncak energi harian dari panel surya ditampilkan dalam Tabel 1.


Tabel 1. Data summary Selama 57 Hari Pengukuran

Data	Nilai
Count	4.294.273
Max	15,4
Average Max	13,438

Grafik pada Gambar 4 memperlihatkan energi yang dihasilkan pada hari ke-52, sedangkan Gambar 5 menunjukkan rata-rata perolehan energi pada hari ke-2 dengan puncak tertinggi sebesar 15,4 Watt pada tanggal 4 Maret 2023.




Gambar 4. Grafik energi pada Hari ke-52



Gambar 5. Grafik Energi pada Hari ke-2

Analisis juga melibatkan perbandingan waktu penyinaran matahari antara lokasi pengukuran dan stasiun meteorologi di Kota Pontianak, yang berjarak sekitar 4,2 kilometer. Data waktu penyinaran matahari dari stasiun BMKG disediakan dalam jam-jam antara pukul 06.00 hingga 18.00. Perbandingan ini menunjukkan perbedaan signifikan dalam waktu penyinaran matahari di dua lokasi tersebut, yang dipengaruhi oleh kondisi langit dan awan. Pada perbandingan lama penyinaran matahari dari data akuisisi akan dihitung sebagai satuan jam dari lokasi akuisisi data dan stasiun meteorologi maritim pontinak, terlihat bahwa waktu penyinaran terlama dari data logger adalah 4,82 jam pada tanggal 8 April 2023. Grafik output daya yang dihasilkan pada waktu ini dapat dilihat pada Gambar 6.



Gambar 6. Waktu Penyinaran Terlama pada Panel Surya

Seluruh data yang dikumpulkan oleh data logger ini akan digunakan sebagai dataset untuk pengembangan model prediksi energi menggunakan metode LSTM (*Long Short-Term Memory*). Model ini akan membantu memprediksi energi yang akan dihasilkan oleh panel surya berdasarkan data cuaca dan kondisi lingkungan pada masa mendatang.

Media Komputasi LSTM

Dalam penelitian ini, pembuatan model LSTM menggunakan layanan Google Colaboratory, sebuah *platform cloud computing* yang mendukung penelitian di bidang machine learning. Google Colaboratory adalah layanan gratis yang memungkinkan peneliti untuk melakukan komputasi machine learning dan deep learning tanpa perlu memiliki sumber daya komputasi yang besar. Layanan ini dapat diakses melalui *browser* dan memerlukan akun Gmail untuk login [14], [15], [16]. Google Colaboratory menggunakan bahasa pemrograman Python sebagai bahasa utamanya. Pengguna gratis memiliki akses ke *resource system* berupa *hardware* Nvidia T4 GPU, RAM 12GB, dan Disk 25GB secara default. Namun, karena data yang akan diproses dalam penelitian ini berjumlah lebih dari 4 juta data, waktu komputasi menggunakan *resource system default* terlalu lama. Oleh karena itu, penelitian ini menggunakan konfigurasi khusus pada Google Colaboratory.

Notebook settings

Runtime type

Python 3 ▾

Hardware accelerator

GPU ▾ ?

GPU type

A100 ▾

Runtime shape

High-RAM ▾

☐ Omit code cell output when saving this notebook

Cancel Save

Gambar 7. Konfigurasi Sistem Komputasi

Gambar 7 menunjukkan konfigurasi sistem komputasi yang digunakan. Penelitian ini menggunakan runtime dengan tipe Python 3 dan dilengkapi dengan hardware accelerator menggunakan GPU Nvidia A100. Dengan konfigurasi ini, peneliti dapat mengakses RAM sebesar 83.5 GB, GPU RAM, dan Disk sebesar 166.8GB. Konfigurasi ini memungkinkan

pemrosesan data yang lebih besar dan kompleks untuk pembuatan model LSTM dengan efisiensi waktu yang optimal.

Pengolahan Data

Data pengukuran yang disimpan dalam format teks (.txt) pada *memory card* diubah menjadi format *Comma Separated Value* (.csv) untuk memungkinkan pengolahan lebih lanjut. Mengingat jumlah baris data yang melebihi 4 juta, file tidak dapat langsung diubah ke format CSV karena batasan Excel yang hanya dapat menampilkan 1 juta baris. Oleh karena itu, data perhari dipisahkan dan disimpan dalam format CSV untuk kemudian diunggah ke Google Drive atau penyimpanan cloud guna mempermudah proses pembacaan. Data tersebut kemudian digabungkan menggunakan Google Colaboratory dan disimpan dalam satu file CSV bernama *combined_data.csv*. File ini digunakan sebagai basis pemrosesan untuk pembuatan model LSTM.

Pembuatan Model LSTM

Ilustrasi model LSTM yang akan digunakan dapat dilihat pada Gambar 2. Proses dimulai dengan mempersiapkan data hasil pengolahan yang telah disatukan dalam satu file CSV. Dalam persiapan data, kolom "Watt", yang mewakili daya keluaran dari energi yang dihasilkan oleh panel surya, dipilih untuk digunakan dalam model LSTM. Data ini kemudian dipecah menjadi dua bagian, yaitu data pelatihan (80% dari total data) dan data uji (20% dari total data) untuk evaluasi model. Setelah pemisahan data, langkah berikutnya melibatkan normalisasi data, memastikan bahwa data yang masuk ke model LSTM berada dalam skala yang sama. Model LSTM yang dibangun menggunakan tipe many to one, dengan 300 timestep (waktu pengukuran) dan 1 fitur (daya keluaran). Dalam arsitektur model ini, terdapat 50 node LSTM pada setiap hidden layer. Kode program 1 menggambarkan pembuatan model LSTM ini.

Kode Program 1. Model LSTM

```
1 model = Sequential()
2 model.add(LSTM(50, return_sequences=True,
3 input_shape=(x_train.shape[1], 1)))
4 model.add(Dropout(0.2))
5 model.add(LSTM(50, return_sequences=False))
6 model.add(Dropout(0.2))
7 model.add(Dense(25, activation='linear'))
8 model.add(Dense(1))
9 model.compile(optimizer='adam',
10 loss='mean_squared_error')
```

Dalam proses ini, optimisasi menggunakan algoritma ADAM, sementara loss function dievaluasi menggunakan mean square error (MSE) [17], [18], [19], yang mengukur sejauh mana perkiraan model mendekati nilai sebenarnya. Proses pelatihan LSTM dimulai dengan menggunakan perintah pada kode program. Dalam proses pelatihan ini, parameter seperti data pelatihan (input dan output), ukuran batch (dengan nilai 1000, yang berarti model memproses 1000 sampel sekaligus dalam setiap iterasi), serta jumlah epoch (mengukur berapa kali seluruh sampel data akan dimasukkan ke model) ditentukan. Selama proses

pelatihan, estimasi waktu pelatihan selesai ditampilkan, bersama dengan loss data yang menggambarkan sejauh mana model mendekati nilai yang seharusnya selama proses pelatihan.


Evaluasi dan Analisis Model LSTM

Dalam penelitian ini, model LSTM digunakan untuk memprediksi data energi yang dihasilkan oleh panel surya. Proses pelatihan model LSTM dievaluasi menggunakan pengukuran Mean Square Error (MSE), yang mengukur seberapa akurat prediksi model terhadap nilai sebenarnya. Dalam penelitian ini, dilakukan perbandingan antara pelatihan model menggunakan dataset dalam satu putaran dan sepuluh putaran. Hasil perbandingan ditunjukkan dalam Tabel 2, yang menunjukkan bahwa model dengan sepuluh putaran pelatihan memiliki nilai MSE yang lebih rendah ($3,2273 \times 10^{-4}$) dibandingkan dengan model satu putaran ($6,2583 \times 10^{-4}$).

Tabel 2. Perbandingan Nilai Pelatihan


Model	Data Training	Epoch	Time (s)	MSE
1	3.435.359	1	340	$6,2583 \times 10^{-4}$
2	3.435.359	10	2081	$3,2273 \times 10^{-4}$

Grafik loss pelatihan untuk model kedua (sepuluh putaran) dapat dilihat pada Gambar 8.




Gambar 8. Grafik Loss Pelatihan Model Ke-2

Selanjutnya, dilakukan pengujian model LSTM yang telah selesai dilatih menggunakan data uji yang belum pernah digunakan selama pelatihan. Model LSTM memprediksi data sebanyak 859.214 data, dan hasil prediksi dari dua model, yaitu model dengan satu putaran dan sepuluh putaran, disajikan dalam Gambar 9 (hasil prediksi model pertama) dan Gambar 10 (hasil prediksi model kedua).



Gambar 9. Hasil Prediksi Model LSTM Pertama



Gambar 10. Hasil Prediksi Model LSTM Kedua

Evaluasi dilakukan menggunakan beberapa metrik, termasuk Mean Square Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan R-squared (R^2). Hasil evaluasi model ditunjukkan dalam Tabel 3.

Tabel 3. Evaluasi Model LSTM

Model	Data Testing	Epoch	Time Predicting (s)	Evaluasi			
				MSE	RMSE	MAE	R^2
1	859.214	1	402	0.02313	0.15209	0.10852	0.99803
2	859.214	10	369	0.04444	0.00456	0.06753	0.99961

Dari hasil evaluasi, kedua model menunjukkan kinerja yang baik, namun model LSTM dengan sepuluh putaran pelatihan menunjukkan performa yang lebih baik. Model ini memiliki MSE yang lebih rendah (0,04444), RMSE yang rendah (0,00456), MAE yang rendah (0,06753), dan R^2 yang tinggi (0,99961). Semua metrik evaluasi tersebut menunjukkan bahwa model LSTM dengan sepuluh putaran pelatihan memiliki kemampuan yang lebih baik dalam memprediksi energi matahari yang dihasilkan oleh panel surya [20], [21], [22]. Selain itu, pada model LSTM terdapat nilai bobot (weight) yang merepresentasikan kontribusi masing-masing node dalam model.

```

Layer: lstm
Weight 1:
[[ 0.62635213  1.0379785  0.9547037 -0.12159048  0.03833437  0.49505144
-0.3957975  0.29756537  0.34771913  0.17806952  0.8701188  1.2203943
-0.24141932  1.841449  0.009514  0.6536246  1.2591285  0.7223183
-0.16205348  0.82064295  0.4708494  0.19248867  0.04858728  0.5464908
-0.00333942 -0.14152883  0.28037184  0.22225259  1.2233859  1.1458364
 0.3012257 -0.43513432 -0.3138064 -0.07569179  0.03382564  0.6775986
 0.02738025 -0.06995333  1.7933694 -0.01272384  0.23143114  0.31199116
-0.12651554  0.46904215 -0.14516243  0.386393 -0.16486274  0.04741043
 1.8449316  0.56823397  0.19998206  0.21560904 -0.14924917 -0.06347486
 0.14482532  0.20358154 -0.386097  0.00835885 -0.26258335  0.11569163
-0.2061214 -0.20616749 -0.02692013  0.12327367 -0.19224276  0.0467884
 0.24439846 -0.29693058 -0.05121593 -0.07310171 -0.01213205  0.22906251
-0.11027194 -0.07300587 -0.12673043  0.18815155 -0.20232815  0.2818679
-0.06938694 -0.03594956  0.02763342 -0.40113592 -0.15251212 -0.0826708
 0.19612454 -0.2810041 -0.19729812 -0.02985736 -0.2709329  0.01425501
 0.11020106  0.22451052 -0.24544269 -0.1410718 -0.17006825 -0.02998778
-0.25176162 -0.13811682  0.00733659 -0.26531777 -0.23608415  0.31504822
-0.27318406  0.21633737 -0.10189526 -0.2478618 -0.374568  0.21678184

```

Gambar 11. Nilai *Weight* pada *Layer* LSTM Model LSTM Kedua

Gambar 11 menunjukkan sebagian dari nilai bobot pada layer LSTM pertama dari model LSTM kedua. Bobot ini merupakan faktor penentu dalam proses prediksi, dan pengoptimalkan bobot ini selama pelatihan model memungkinkan model LSTM untuk menghasilkan prediksi yang akurat dan mendekati nilai sebenarnya.

Analisis Prediksi

Prediksi adalah proses membuat estimasi tentang apa yang mungkin terjadi di masa depan dengan menggunakan data dan informasi dari masa lalu. Ini melibatkan analisis data historis atau tren untuk memahami pola dan hubungan dalam data tersebut. Tujuan utama dari prediksi adalah mendapatkan pemahaman yang lebih baik tentang kemungkinan masa depan berdasarkan informasi yang telah ada. Metode prediksi melibatkan berbagai pendekatan seperti statistik, analisis data, dan pembelajaran mesin[23], [24]. Metode-metode ini memanfaatkan pola historis, kausalitas, dan informasi relevan lainnya untuk membangun model atau algoritma yang dapat memperkirakan nilai atau peristiwa di masa depan. Prediksi memiliki peran penting dalam berbagai bidang seperti ilmu pengetahuan, ekonomi, bisnis, dan teknologi, membantu orang membuat keputusan yang lebih informasional dan mempersiapkan langkah-langkah yang tepat untuk masa depan.

KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa sistem alat pengukuran energi daya output panel surya dengan data logger berhasil mengumpulkan data sebanyak 4.294.273 pengukuran dalam interval waktu 1-3 detik, mencakup periode dari 3 Maret 2023 hingga 28 April 2023, dengan daya maksimum yang tercatat sebesar 15.4 Watt. Sistem perhitungan menggunakan model LSTM berbasis cloud computing di Google Colaboratory dapat membuat, melatih, dan menguji model LSTM dengan efektif. Evaluasi model menunjukkan bahwa penggunaan lebih dari satu epoch dalam pelatihan meningkatkan performa model, meskipun perubahan nilai MSE setelah epoch kedua tidak signifikan. Prediksi energi matahari dengan model ini menghasilkan evaluasi yang sangat baik dengan MSE sebesar 0.04444, RMSE sebesar 0.00456, MAE sebesar 0.06753, dan R2 sebesar 0.99961. Sebagai saran, disarankan untuk meningkatkan stabilitas dalam desain akuisisi data guna mengurangi delay perekaman dan untuk mempertimbangkan alternatif catu daya dari panel surya itu sendiri. Penggunaan panel surya dengan spesifikasi yang lebih besar

disarankan untuk skala rumah tangga agar prediksi menjadi lebih akurat dan memungkinkan pemantauan secara online. Selain itu, perlu mempertimbangkan peningkatan periode perekaman data agar dapat merepresentasikan pola energi matahari secara lebih lengkap, yang dapat memberikan informasi yang lebih detail dan akurat untuk analisis lebih lanjut.

REFERENSI

- [1] S. D. J. Ketenagalistrikan, "Statistik Kelistrikan Tahun 2020."
- [2] H. B. Tambunan, *Sistem Pembangkit Listrik Tenaga Surya*. Deepublish.
- [3] N. Rochyani *et al.*, "No Title."
- [4] E. Erwin *et al.*, "No Title," in *PENGANTAR & PENERAPAN INTERNET OF THINGS: Konsep dasar & Penerapan IoT di berbagai Sektor*, PT. Sonpedia Publishing Indonesia.
- [5] R. I. Mukromin and M. K. Asy'ari, "Prediksi Daya Panel Surya Kapasitas 50 Wp Menggunakan Model Regresi Linier Majemuk," *Jurnal Teknologi Bahan Dan Barang Teknik*, vol. 10, no. 2, pp. 58–65.
- [6] T. A. Priatama, Y. Apriani, and M. Danus, "Sistem Monitoring Solar Cell Menggunakan Mikrokontroller Arduino Uno R3 Dan Data Logger Secara Real Time," *PROSIDING SNITT POLTEKBA*, vol. 4, pp. 249–253.
- [7] D. Erwanto and T. Sugiarto, "Sistem Pemantauan Arus Dan Tegangan Panel Surya Berbasis Internet of Things," *Multitek Indonesia*, vol. 14, no. 1, pp. 1–12.
- [8] E. P. Cynthia, N. Yanti, Y. Fitriani, and Y. Yusra, *No Title*. Prediksi Radiasi Matahari Dengan Penerapan.
- [9] N. A. Khafaf, M. Jalili, and P. Sokolowski, "Application of Deep Learning Long Short-Term Memory in Energy Demand Forecasting," *ArXiv*.
- [10] F. A. Nugraha, N. H. Harani, and R. Habibi, *Analisis Sentimen Terhadap Pembatasan Sosial Menggunakan Deep Learning*. Kreatif.
- [11] M. S. Iswahyudi *et al.*, "No Title," in *APLIKASI MACHINE LEARNING DI BERBAGAI BIDANG: Solusi Cerdas Untuk Masa Depan*. PT. Sonpedia Publishing Indonesia.
- [12] A. Agusta, I. Ernawati, and A. Muliawati, "Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory," *Informatik: Jurnal Ilmu Komputer*, vol. 17, no. 2, pp. 164–173.
- [13] M. K. Anam and D. A. Jakaria, "Sistem Prediksi Harga Kripto Dengan Metode Regresi," *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, vol. 10, no. 2, pp. 467–479.
- [14] T. Carneiro, R. V. M. Da Nobrega, T. Nepomuceno, G. Bin Bian, V. H. C. De Albuquerque, and P. P. R. Filho, "Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications," *IEEE Access*, vol. 6, 2018, doi: 10.1109/ACCESS.2018.2874767.
- [15] F. Wilyani, Q. Nuryan Arif, and F. Aslimar, "Pengenalan Dasar Pemrograman Python Dengan Google Colaboratory," *Jurnal Pengabdian Pada Masyarakat Indonesia*, vol. 3, no. 1, 2024.
- [16] Dr. S. R. Sukhdeve and S. S. Sukhdeve, "Google Colaboratory," in *Google Cloud Platform for Data Science*, 2023. doi: 10.1007/978-1-4842-9688-2_2.
- [17] M. A. A. Nawi, W. M. A. W. Ahmad, M. S. M. Ibrahim, M. Mamat, M. F. Khamis, and M. A. Mohamed, "Proving the efficiency of alternative linear regression model based on mean square error (MSE) and average width using aquaculture data," *International Journal of Recent Technology and Engineering*, vol. 8, no. 2 Special Issue 3, 2019, doi: 10.35940/ijrte.B1065.0782S319.
- [18] F. Widiastuti, W. Murniati, and Saikin, "Penerapan Data Mining Untuk Memprediksi Penjualan Kain Tenun Mnggunakan Regresi Linear Studi Kasus: Ud.Bintang Remawe Sukarare," *Jurnal Ilmiah Teknik Mesin, Elektro, dan Komputer*, vol. 2, no. 1, 2022.
- [19] Susilawati and Muhathir, "Analysis of The Influence Activation Function, Learning Rate And Momentum in Determining Mean Square Error (MSE) in Restricted Boltzmann Machines (RBM) Neural Network," *Journal of Information Technology Education: Research*, vol. 2, no. 2, 2019, doi: 10.31289/jite.v2i2.2162.
- [20] M. A. Majeed, H. Z. M. Shafri, Z. Zulkafli, and A. Wayayok, "A Deep Learning Approach for Dengue Fever Prediction in Malaysia Using LSTM with Spatial Attention," *Int J Environ Res Public Health*, vol. 20, no. 5, 2023, doi: 10.3390/ijerph20054130.
- [21] B. Gülmez, "Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm," *Expert Syst Appl*, vol. 227, 2023, doi: 10.1016/j.eswa.2023.120346.
- [22] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network," *Physica D*, vol. 404, 2020, doi: 10.1016/j.physd.2019.132306.

-
- [23] E. K. Adhitya, R. Satria, and H. Subagyo, "Komparasi Metode Machine Learning dan Metode Non Machine Learning untuk Estimasi Usaha Perangkat Lunak," *IlmuKomputer.com Journal of Software Engineering*, vol. 1, no. 2, 2015.
- [24] V. Rafianto, G. Djoyowasito, M. B. Hermanto, and Y. Wibisono, "PENDUGAAN REDUKSI UKURAN BERBASIS MODEL ALGORITMA PERHITUNGAN BALIK PADA PENEPUNGAN CANGKANG RAJUNGAN MENGGUNAKAN BALL-MILL," *Jurnal Ilmiah Rekayasa Pertanian dan Biosistem*, vol. 9, no. 1, 2021, doi: 10.29303/jrpb.v9i1.217.
-