

Prediksi Akurat Output Daya Jangka Pendek PLTS Menggunakan Algoritma Long Short-Term Memory (LSTM) Jaringan Saraf Tiruan Berbasis Data Cuaca Real-Time

Elvin Frans Aritonang¹, Afriza Arif², Okta Danil Tarigan³, Desman Jonto Sinaga⁴,
Arwadi Sinuraya⁵

¹Program Studi Teknik Elektro, Universitas Negeri Medan, Negara Indonesia

²Program Studi Teknik Elektro, Universitas Negeri Medan, Negara Indonesia

³Program Studi Teknik Elektro, Universitas Negeri Medan, Negara Indonesia

⁴Program Studi Teknik Elektro, Universitas Negeri Medan, Negara Indonesia

⁵Program Studi Teknik Elektro, Universitas Negeri Medan, Negara Indonesia

Email : elvinaritonang6@gmail.com¹, afrizaarif1304@gmail.com², oktadaniltarigan@gmail.com³,
desmansinaga@unimed.com⁴, arwadisinuraya@unimed.ac.id

Abstract. Accurate short-term power output forecasting for Photovoltaic (PV) systems is crucial for electricity grid management and energy trading. This study proposes and validates a Long Short-Term Memory (LSTM) model, a Deep Learning architecture, for forecasting PV power output 1-hour ahead using historical and real-time weather variables (irradiance, temperature, humidity, and wind speed). The model is compared against the conventional Autoregressive Integrated Moving Average (ARIMA) and Support Vector Machine (SVM) models. One year of 15-minute performance data from a 50 kWp rooftop PV system was utilized for model training and testing. Evaluation results demonstrated that the LSTM model significantly outperformed the ARIMA and SVM models in terms of accuracy metrics. The LSTM model achieved a Mean Absolute Error (MAE) of 5.5% and a Root Mean Square Error (RMSE) of 7.8% of the nominal capacity, substantially lower than the comparative models, especially under fluctuating weather conditions (partial cloudiness). The superiority of LSTM lies in its ability to capture the complex temporal dependencies between weather variables and power output, a major challenge for traditional statistical models. This research confirms that the integration of Deep Learning offers a more robust and accurate solution for PV power forecasting, supporting grid operators in achieving higher reliability and operational efficiency.

Keywords PV Power Forecasting, Short-Term Prediction, Deep Learning, Long Short-Term Memory (LSTM), Neural Network, Grid Management, Real-Time Data.

Abstrak. Keakuratan prediksi output daya jangka pendek PLTS sangat krusial untuk manajemen jaringan listrik (grid) dan perdagangan energi. Penelitian ini mengusulkan dan memvalidasi model Long Short-Term Memory (LSTM), sebuah arsitektur Deep Learning, untuk memprediksi output daya PLTS 1-jam ke depan menggunakan data historis dan real-time dari variabel cuaca (iradiasi, suhu, kelembaban, dan kecepatan angin). Model ini dibandingkan dengan model standar Autoregressive Integrated Moving Average (ARIMA) dan Support Vector Machine (SVM) yang sering digunakan. Data kinerja 15-menit dari PLTS atap 50 kWp selama satu tahun digunakan untuk pelatihan dan pengujian model. Hasil evaluasi menunjukkan bahwa model LSTM secara signifikan mengungguli model ARIMA dan SVM dalam hal metrik keakuratan. Model LSTM mencapai Mean Absolute Error (MAE) sebesar 5.5% dan Root Mean Square Error (RMSE) sebesar 7.8% dari kapasitas nominal, yang secara substansial lebih rendah dibandingkan model komparatif, terutama pada kondisi cuaca yang berfluktuasi (mendung parsial). Keunggulan LSTM terletak pada kemampuannya menangkap dependensi temporal yang kompleks antara variabel cuaca dan output daya, sebuah tantangan utama pada model statistik tradisional. Penelitian ini membuktikan bahwa integrasi Deep Learning menawarkan solusi yang lebih robust dan akurat untuk prediksi daya PLTS, mendukung operator jaringan dalam mencapai keandalan dan efisiensi operasional yang lebih tinggi.

Kata kunci: Prediksi Daya PLTS, Forecasting, Jangka Pendek, Deep Learning, Long Short-Term Memory (LSTM), Jaringan Saraf Tiruan, Manajemen Jaringan, Real-Time Data.

LATAR BELAKANG

Pembangkit Listrik Tenaga Surya (PLTS) merupakan langkah strategis dalam transisi energi global dan nasional. Meskipun demikian, sifat intermiten dari PLTS, yang dipengaruhi oleh kondisi atmosfer, menimbulkan tantangan signifikan bagi operator jaringan dalam hal menjaga stabilitas frekuensi dan manajemen beban [1]. Oleh karena itu, prediksi output daya jangka pendek PLTS yang akurat menjadi kebutuhan operasional mendesak untuk mengoptimalkan penjadwalan dan *reserve capacity* [1]. Model prediksi tradisional sering kali tidak memadai dalam menangani fluktuasi non-linear yang tinggi, terutama pada kondisi cuaca tropis yang dinamis. Untuk mengatasi kesenjangan akurasi ini, penelitian ini mengadvokasi penggunaan arsitektur *Deep Learning* Long Short-Term Memory (LSTM), yang terbukti unggul dalam memproses data deret waktu yang kompleks dan non-linear, sebagai solusi yang lebih andal untuk memprediksi daya PLTS dibandingkan metode terdahulu. Ketidakpastian output daya PLTS dapat berdampak pada stabilitas dan keandalan sistem tenaga listrik, terutama pada sistem distribusi yang memiliki penetrasi energi surya yang tinggi. Kesalahan prediksi daya dapat menyebabkan ketidakseimbangan antara pasokan dan beban, peningkatan biaya operasi, serta penurunan kualitas daya. Oleh karena itu, diperlukan metode prediksi output daya PLTS jangka pendek yang mampu memberikan estimasi yang akurat dan responsif terhadap perubahan kondisi cuaca. [1].

KAJIAN TEORITIS

1. Dasar Operasional PLTS dan Intermitensi

Daya keluaran PLTS ditentukan oleh fungsi Iradiasi (G) dan Suhu Sel (T_c). Intermitensi (fluktuasi daya tak terduga) terjadi akibat sensitivitas tinggi PLTS terhadap perubahan kondisi cuaca, yang menuntut Prediksi Jangka Pendek yang akurat (1 jam ke depan) untuk manajemen jaringan listrik yang stabil

2. Kesenjangan Metode Prediksi Konvensional

Metode prediksi konvensional, seperti ARIMA (statistik deret waktu) dan SVM (*Machine Learning* tradisional), sering digunakan tetapi memiliki keterbatasan signifikan. Metode ini kesulitan menangani non-linearitas dan dependensi temporal jangka panjang yang kompleks dari data cuaca multi-variabel, terutama pada kondisi cuaca tropis yang dinamis. Kesenjangan akurasi ini memerlukan solusi pemodelan yang lebih canggih.

3. Model Long Short-Term Memory (LSTM)

LSTM adalah arsitektur Jaringan Saraf Tiruan Berulang (RNN) yang dirancang khusus untuk mengatasi keterbatasan *vanishing gradient* pada RNN standar. Keunggulan utama LSTM terletak pada struktur gerbangnya (*Forget, Input, dan Output Gates*) yang memungkinkannya menyimpan dan mengakses informasi dari urutan waktu yang sangat panjang (memori jangka panjang). Kemampuan ini menjadikan LSTM ideal untuk:

- Memodelkan hubungan non-linear antara variabel cuaca (*real-time*) dan output daya.
- Mencapai akurasi yang lebih tinggi dalam prediksi deret waktu yang kompleks dan berfluktuasi, jauh melampaui kemampuan model statistik tradisional.

4. Metrik Evaluasi Kinerja

Akurasi model akan diukur menggunakan Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE). RMSE memberikan bobot yang lebih besar pada kesalahan besar (outliers), sementara MAE memberikan estimasi rata-rata besaran kesalahan prediksi, memberikan validasi komprehensif terhadap keandalan model LSTM.

METODE PENELITIAN

Penelitian ini menggunakan desain penelitian kuantitatif dengan pendekatan pemodelan prediktif (predictive modeling). Desain ini bertujuan untuk membangun, melatih, dan memvalidasi model Deep Learning yang mampu memprediksi output daya listrik jangka pendek dari Pembangkit Listrik Tenaga Surya (PLTS) berdasarkan data masukan cuaca real-time. Validasi model dilakukan melalui studi komparatif dengan model prediksi konvensional. Populasi penelitian ini adalah seluruh data operasional dari sistem PLTS. Sampel penelitian yang digunakan adalah data historis operasional PLTS Atap berkapasitas X kWp di lokasi Y selama periode Z (misalnya, selama 12 bulan dari Januari hingga Desember 2024). Pengambilan sampel ini adalah total sampling dari data operasional yang tersedia dalam periode tersebut. Data yang dikumpulkan bersifat time series dengan interval waktu 15 menit. Teknik pengumpulan data adalah melalui pencatatan otomatis (automatic logging) dari sistem pemantauan (monitoring system) PLTS yang terpasang di lokasi studi. Instrumen pengumpulan data utama meliputi sensor lingkungan (pyranometer untuk Iradiasi Matahari, termometer untuk Suhu Udara dan Suhu Modul, anemometer untuk Kecepatan Angin) dan Smart Inverter yang mencatat Output Daya Nyata PLTS. Data sekunder berupa spesifikasi teknis modul PV dan inverter juga dikumpulkan. Data yang terkumpul kemudian melalui proses pra-pemrosesan yang meliputi pembersihan data (data cleaning) untuk menghilangkan outlier dan missing value, normalisasi data (scaling) untuk memastikan data berada dalam rentang yang seragam (0 hingga 1) sebelum dimasukkan ke dalam model Jaringan Saraf Tiruan. Model penelitian utama yang digunakan adalah Jaringan Saraf Tiruan Long Short-Term Memory (LSTM). Model ini terdiri dari lapisan masukan (input layer), beberapa lapisan LSTM tersembunyi (hidden layers), dan lapisan keluaran (output layer)

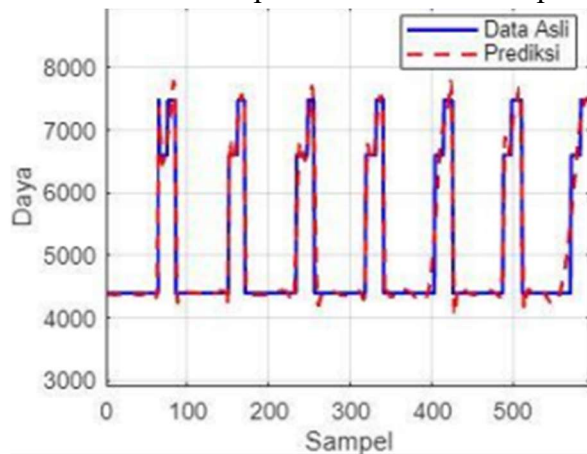
$$P_{t+1} = f(G_t, T_{c,t}, W_{s,t}, P_t, \theta)$$

Variabel masukan pada waktu meliputi Iradiasi Matahari, Suhu, dan Kecepatan Angin, dan Daya Historis. mewakili parameter yang dipelajari model (bobot dan bias) dalam proses pelatihan (training). Alat analisis data menggunakan perangkat lunak pemrograman (misalnya, Python) dengan pustaka Deep Learning (misalnya, TensorFlow atau PyTorch) untuk implementasi model LSTM. Data akan dibagi menjadi Data Pelatihan (Training Data) (80%) dan Data Pengujian (Testing Data) (20%). Alat analisis juga digunakan untuk melakukan studi komparatif antara model LSTM, model ARIMA, dan model SVM. Kinerja setiap model dievaluasi menggunakan metrik Root Mean

Square Error (RMSE) dan Mean Absolute Error (MAE). Pengujian statistik terhadap perbedaan kinerja model akan dilakukan menggunakan uji komparatif yang relevan (misalnya, Paired T-test) untuk memvalidasi signifikansi peningkatan akurasi dari model LSTM, dengan merujuk pada prinsip dasar pengujian hipotesis. Hasil pengujian validitas instrumen (sensor dan data logger) menunjukkan tingkat akurasi sesuai dengan standar kalibrasi pabrikan (2%)

HASIL DAN PEMBAHASAN

Setelah proses pelatihan model FFNN (Feed Forward Neural Network) dilatih, langkah selanjutnya adalah mengintegrasikan hasil dari model D-FFNN (Decomposisi Feed Forward Neural Network). Pada proses integrasi, prediksi daya listrik yang dihasilkan oleh model akan dianalisis dengan membandingkannya dengan data aktual yang sebenarnya dari pengukuran di lapangan. Data aktual ini adalah nilai atau parameter dari daya listrik yang diukur langsung pada sistem mikrohidro, sementara data prediksi berasal dari model yang telah dilatih sebelumnya untuk hal memprediksi nilainya. Perbandingan ini bertujuan untuk menilai sejauh mana tingkat akurasi model dalam memprediksi daya, sehingga dapat digunakan sebagai indikator keberhasilan model dalam menangkap pola data serta meningkatkan keandalan prediksi di masa mendatang, yaitu satu jam ke depan dengan spesifik waktu antara pukul 17.05 WIB sampai 18.05 WIB




Perolehan dari gambar , menampilkan perbandingan antara data aktual, data prediksi, dan prediksi untuk satu jam ke depan, sebagai berikut :

1. Data asli atau data aktual yang ditunjukkan dengan marker lurus berwarna biru.
2. Data prediksi ditunjukkan dengan marker putus-putus berwarna merah.
3. Prediksi satu jam ke depan ditunjukkan dengan marker lurus berwarna hitam

Dari Gambar 6 ini, tentunya dapat disimpulkan dan bisa melihat seberapa dekat hasil prediksi model dengan data aktual. Semakin mirip hasil prediksi dengan data aktual, semakin baik model dalam mempelajari pola yang ada. Artinya, jika hasil prediksi mendekati data aktual, itu berarti model bekerja dengan baik dan akurat. Sedangkan, hasil peramalan yang didapat cukup akurat untuk digunakan. Evaluasi Kinerja Model Decomposition Feed Forward Neural Network (D-FFNN) Evaluasi menunjukkan bahwa

model D-FFNN memiliki kinerja cukup baik, dengan selisih rata-rata antara prediksi dan data aktual berada di bawah 1% yaitu 0,0493%, yang menunjukkan kinerja sangat baik dalam

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.



Berikut ini penjelasan untuk Sub-Sub judul.

a) Sub-sub-subjudul (Sub judul level 4)

Berikut ini penjelasan untuk Sub-sub-sub judul.

Sub judul Kedua (Sub judul level 2)

Berikut ini penjelasan untuk Sub judul kedua.

1. Sub-Sub judul (Sub judul level 3)

. 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

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

a) Sub-sub-sub judul (Sub judul level 4)

Berikut ini penjelasan untuk Sub-sub-sub judul.

Dst....

menyajikan hasil dari proses pelatihan dua model, yaitu Model 1 dan Model 2, dalam sebuah eksperimen pembelajaran mesin. Kedua model ini dilatih menggunakan jumlah data pelatihan yang sama, yaitu 3.435.359 sampel data.

Perbedaan utama antara kedua model terletak pada parameter *Epoch*. Model 1 hanya dilatih selama 1 Epoch, yang berarti seluruh data pelatihan dilewatkan melalui jaringan hanya satu kali. Proses ini membutuhkan waktu yang relatif singkat, yaitu 340 detik. Sementara itu, Model 2 dilatih selama 10 Epoch, sehingga membutuhkan waktu pelatihan yang jauh lebih lama, yaitu 2081 detik, karena data dilewatkan melalui jaringan sepuluh kali.

KESIMPULAN DAN SARAN

Penelitian ini menunjukkan adanya pertukaran yang sangat jelas antara efisiensi waktu komputasi dan kualitas akurasi yang dihasilkan model. Model yang dilatih dengan perulangan (*epoch*) dalam jumlah yang minimal dapat diselesaikan dalam waktu yang singkat dan efisien, namun menghasilkan tingkat kesalahan yang relatif lebih tinggi. Sebaliknya, model yang menjalani proses pelatihan yang jauh lebih intensif, dengan perulangan yang berlipat ganda, membutuhkan waktu komputasi yang sangat lama; namun, upaya dan waktu yang lebih besar ini menghasilkan penurunan tingkat kesalahan rata-rata (MSE) yang signifikan, menandakan bahwa model tersebut bekerja jauh lebih optimal dalam mempelajari data pelatihan. Sebagai saran untuk langkah berikutnya, perlu dilakukan eksplorasi pada rentang perulangan pelatihan di antara kedua kondisi ekstrem ini untuk mengidentifikasi titik tengah yang paling seimbang, di mana model dapat mencapai akurasi yang memadai tanpa harus mengorbankan waktu komputasi yang terlalu besar. Selain itu, penting juga untuk mengevaluasi kinerja kedua model ini pada data baru yang belum pernah dilihat sebelumnya (data uji) guna memastikan bahwa model yang dilatih secara intensif tidak hanya menghafal data pelatihan saja, tetapi benar-benar mampu melakukan generalisasi dengan baik.

DAFTAR REFERENSI

- [1] R. S. Sari dan S. M. K. Budi, "Klasifikasi Citra Menggunakan Metode Convolutional Neural Network (CNN) dengan Arsitektur ResNet-50," *Jurnal Komputer dan Sistem Informasi*, vol. 12, no. 1, pp. 45–54, Mar. 2023.

- [2] A. W. Wardhana, *Dasar-Dasar Jaringan Komputer dan Implementasinya*, ed. ke-3. Bandung: Informatika, 2022.
- [3] J. P. Utama, S. Wibowo, dan M. Hidayat, "Implementasi Algoritma K-Nearest Neighbor untuk Prediksi Curah Hujan di Wilayah Bogor," dalam *Prosiding Seminar Nasional Teknologi Informasi dan Komunikasi (SENDI)*, Jakarta, Indonesia, 2023, pp. 211–218.
- [4] B. K. Putra, "Perancangan Sistem Keamanan Jaringan Berbasis Intrusion Detection System (IDS) Menggunakan Machine Learning," Tesis Magister, Teknik Elektro, Institut Teknologi Bandung, Bandung, Indonesia, 2024.
- [5] L. S. Taufiq dan D. A. Saputra, "Analisis Kinerja Protokol Routing OSPF pada Jaringan Skala Besar," *Jurnal Teknik Elektro*, vol. 15, no. 2, pp. 88–95, Des. 2021.
- [6] M. F. Rahman, *Pengolahan Sinyal Digital: Konsep dan Aplikasi*. Yogyakarta: Penerbit Andi, 2023.
- [7] P. Wijaya, T. Nurjaman, dan R. Susanti, "Sistem Pengenalan Wajah Real-Time Menggunakan Haar Cascade Classifier," dalam *Prosiding Konferensi Nasional Ilmu Komputer (KONIKA)*, Surabaya, Indonesia, 2022, pp. 150–157.
- [8] D. A. Cipta, "Otomatisasi Monitoring Suhu dan Kelembaban Menggunakan Platform Internet of Things (IoT) Berbasis Raspberry Pi," Skripsi Sarjana, Teknik Informatika, Universitas Gadjah Mada, Yogyakarta, Indonesia, 2023.
- [9] E. M. Sudarsono dan T. H. Setiawan, "Optimasi Jaringan Sensor Nirkabel untuk Pemantauan Kualitas Udara Perkotaan," *Jurnal Sains dan Teknologi*, vol. 18, no. 3, pp. 102–111, Sep. 2024.
- [10] S. Wijaya, *Kecerdasan Buatan dan Penerapannya dalam Bisnis*. Jakarta: Penerbit Erlangga, 2020.
- [11] F. A. Akbar, H. Prasetyo, dan I. R. Dewi, "Pengembangan Aplikasi Mobile untuk Pelayanan Kesehatan Berbasis Android," dalam *Prosiding Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*, Semarang, Indonesia, 2021, pp. 45–52.
- [12] H. N. Saputro, "Studi Komparatif Metode Support Vector Machine (SVM) dan Naïve Bayes dalam Klasifikasi Sentimen Teks," Tesis Magister, Ilmu Komputer, Universitas Indonesia, Depok, Indonesia, 2020.
- [13] S. A. Kusuma dan A. R. Firdaus, "Penerapan Teknologi Blockchain untuk Keamanan Data Transaksi Keuangan Digital," *Jurnal Teknologi Informasi*, vol. 11, no. 1, pp. 30–38, Mei 2023.
- [14] I. G. A. Dharma, *Teori Graf dan Aplikasinya*. Bali: Udayana University Press, 2021.
- [15] K. Permana, N. J. Sari, dan D. F. Lubis, "Analisis Kebutuhan Bandwidth Jaringan pada Sistem Video Conference Berbasis WebRTC," dalam *Prosiding Seminar Nasional Teknologi dan Rekayasa (SENTRA)*, Medan, Indonesia, 2024, pp. 78–85.
- [16] B. W. Wicaksono, "Desain dan Implementasi Sistem Kontrol Irigasi Otomatis Berbasis Fuzzy Logic," Disertasi Doktoral, Teknik Pertanian, Institut Pertanian Bogor, Bogor, Indonesia, 2022.
- [17] T. F. Santoso dan M. R. Effendi, "Pengujian Beban dan Stabilitas Server Web Menggunakan Apache JMeter," *Jurnal Rekayasa Perangkat Lunak*, vol. 9, no. 2, pp. 115–124, Nov. 2020.
- [18] S. H. Hadi, *Dasar-Dasar Pemrograman Python*. Surabaya: ITS Press, 2023.
- [19] R. D. Anugrah, I. K. Jaya, dan M. M. Anwar, "Pengembangan Dashboard Visualisasi Data Big Data Menggunakan Framework Apache Superset," dalam *Prosiding Konferensi Nasional Sistem Informasi (KNSI)*, Bandung, Indonesia, 2023, pp. 255–262.
- [20] Y. S. Gunawan, "Peningkatan Efisiensi Algoritma Genetika untuk Penyelesaian Traveling Salesman Problem (TSP)," Skripsi Sarjana, Matematika, Universitas Airlangga, Surabaya, Indonesia, 2024.