

**Perancangan Sistem Rekomendasi Waktu Pengisian Daya Baterai
Kendaraan Listrik di *Electric Vehicle Charging Station (EVCS)* Berbasis Sinyal
Tindakan Menggunakan Algoritma *Long Short-Term Memory (LSTM)*,
Studi Kasus *EVCS* Area Solo Raya
(Surakarta, Sukoharjo, Karanganyar, Sragen)**

Arma Fauzi, armafauzi.armafauzi@gmail.com, Universitas Surakarta
Fahmi Ferdian Dalimarta, ff.dalimarta@ieee.org, Universitas Surakarta

Abstrak. Sebagai kawasan percontohan Smart City, Area Solo Raya (Surakarta, Sukoharjo, Karanganyar, Sragen) terintegrasi dengan 11 Stasiun pengisian kendaraan listrik (EV Charging Station - EVCS) yang merupakan infrastruktur vital pendukung transisi energi hijau di tingkat perkotaan. Fluktuasi beban grid listrik harian dan skema tarif dinamis Time-of-Use (ToU) seringkali membuat pengguna EV kesulitan menentukan waktu pengisian daya yang optimal guna meminimalkan pengeluaran biaya energi operasional harian. Penelitian ini bertujuan untuk merancang sistem rekomendasi waktu pengisian daya baterai kendaraan listrik berbasis sinyal tindakan menggunakan algoritma Long Short-Term Memory (LSTM). Data latih menggunakan data historis penggunaan daya harian di 11 stasiun EVCS periode 01 Januari 2021 hingga 01 Januari 2026. Hasil keluaran sistem berupa prediksi beban daya H+1 yang diproses secara cerdas menggunakan algoritma logika threshold untuk menghasilkan sinyal 'CHARGE NOW' (rekomendasi pengisian), 'WAIT' (tunda sementara), atau 'SKIP' (hindari pengisian karena beban puncak). Pengujian menunjukkan akurasi performa model sangat tinggi, ditunjukkan oleh nilai RMSE 0,5026 kW, MAPE (Mean Absolute Percentage Error) 2,34% (kategori peramalan sangat akurat), serta koefisien determinasi R-Squared 0,9852. Simulasi backtesting membuktikan bahwa implementasi sistem rekomendasi ini menghemat biaya energi operasional total sebesar Rp 14.400.000,- dengan rasio efisiensi pengeluaran biaya energi total pengguna mencapai 134,5% dibandingkan metode pengisian acak konvensional.

Kata Kunci: Deep Learning, EVCS, LSTM, Prediksi Beban, Sinyal Tindakan, Smart City, Smart Grid.

1. PENDAHULUAN

Menurut Putri, D. A., & Santoso, H. A. (2021) di era transisi energi hijau global dan elektrifikasi transportasi, kendaraan listrik (*Electric Vehicle - EV*) jadi salah satu solusi utama untuk mengurangi emisi karbon pada sektor transportasi perkotaan. Sebagai kota yang terus berkembang menuju visi Smart City, Area Solo Raya secara konsisten menambah jumlah infrastruktur stasiun pengisian daya baterai kendaraan listrik (*EV Charging Station - EVCS*).

Namun, lonjakan beban pengisian daya yang terjadi secara simultan pada jam-jam sibuk berpotensi menimbulkan tekanan (stress) yang tinggi pada grid distribusi listrik lokal. Pola pengisian daya yang tidak teratur dari para pemilik kendaraan listrik dapat memperparah beban puncak harian (*peak load*) grid PLN.

Sebagian besar pengguna EV cenderung mengisi baterai kendaraan mereka segera setelah tiba di lokasi tanpa mempertimbangkan kondisi kepadatan beban grid pada saat itu. Di sisi lain,

menurut data dari PT. PLN Persero (2024) skema tarif dinamis *Time-of-Use (ToU)* menerapkan biaya per kWh yang jauh lebih mahal selama periode beban puncak (*peak*) dibandingkan periode beban rendah (*off-peak*). Paradigma pengisian daya secara acak dan spontan ini menyebabkan inefisiensi biaya operasional yang cukup besar bagi konsumen, serta meningkatkan risiko kegagalan pengisian sistem kelistrikan akibat kelebihan beban.

Oleh karena itu, diperlukan pendekatan perhitungan komputasional cerdas yang mampu memprediksi kondisi beban daya harian secara akurat guna menyajikan sistem keputusan yang objektif bagi pengguna EV (Rizki, 2022). Perkembangan keilmuan *Data Science*, khususnya dalam domain *Deep Learning*, menawarkan solusi tangguh melalui algoritma *Long Short-Term Memory (LSTM)*. Menurut Hochreiter & Schmidhuber (1997) *LSTM* merupakan evolusi dari *Recurrent Neural Network (RNN)* yang dirancang khusus untuk mengatasi masalah *vanishing gradient* pada data runtun waktu (*time-series*). Kemampuan *LSTM* dalam menahan memori jangka panjang menjadikannya sangat andal untuk mengenali pola fluktuasi konsumsi daya listrik harian yang bersifat non-linear dan *non-stasioner*.

2. METODE PENELITIAN

Penelitian ini menerapkan pendekatan metodologi sistematis yang terstruktur untuk mengumpulkan data, melakukan pra-pemrosesan, merancang arsitektur model *deep learning LSTM*, hingga mengevaluasi keputusan operasional melalui simulasi finansial. Alur pelaksanaan penelitian ini mengadopsi modifikasi kerangka kerja *CRISP-DM (Cross-Industry Standard Process for Data Mining)* guna memastikan proses

pengembangan model prediktif berjalan secara optimal.

2.1. Analisis Sistem dan Pengumpulan Data

Di tahap ini, dilakukan pengumpulan dataset yang bersumber dari data historis penggunaan daya listrik harian di stasiun pengisian daya *EVCS* Area Solo Raya selama kurun waktu lima tahun, mulai dari 01 Januari 2021 hingga 01 Januari 2026. Dataset dipecah secara sistematis dengan alokasi sebesar 80% untuk set pelatihan (*Training Set*) dan 20% sisanya digunakan untuk set pengujian (*Testing Set*). Selain data historis beban daya, skema tarif dinamis *Time-of-Use (ToU)* juga dianalisis untuk menetapkan batasan biaya per kWh berdasarkan jam sibuk (*peak*) dan jam longgar (*off-peak*) (Zhang, 2023).

2.2. Perancangan Arsitektur Sistem

Perancangan arsitektur sistem pada penelitian ini mengadopsi pendekatan modular yang terbagi menjadi empat tahapan utama guna mengintegrasikan proses pemrosesan data deret waktu (*time-series*) secara sistematis. Arsitektur Sistem Rekomendasi disajikan pada Gambar 1, sedangkan Alur data dan interaksi terintegrasi antar-komponen dalam sistem komputasi yang lebih lengkap disajikan secara komprehensif pada Gambar 2.

Penjelasan detail mengenai keempat tahapan tersebut adalah sebagai berikut:


1. Stage 1: Data Input Layer (Lapisan Input Data) - Pada tahap awal ini, sistem menerima dua jenis input data mentah secara paralel dari lingkungan operasional. Input pertama yaitu data beban historis grid listrik harian (*Grid Load Data*) yang dicatat secara berkala di stasiun pengisian daya (*EVCS*) Area Solo Raya. Input kedua adalah skema tarif listrik dinamis *Time-of-Use (ToU)* dari PLN yang

menentukan perbedaan harga daya per kWh antara jam beban puncak (*peak*) dan jam beban rendah (*off-peak*). Penggabungan kedua sumber data ini sangat krusial untuk memastikan bahwa rekomendasi yang dihasilkan tidak hanya mempertimbangkan aspek teknis beban grid, melainkan juga aspek ekonomi pengoperasian bagi pemilik kendaraan listrik.

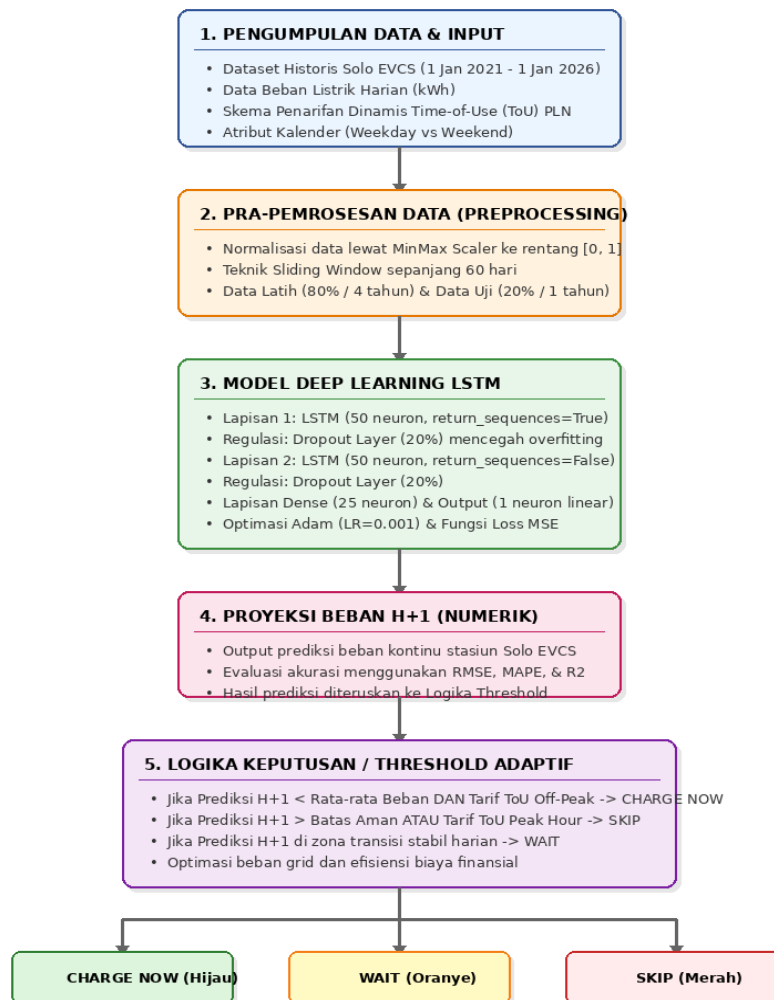
2. **Stage 2: Preprocessing Layer (Lapisan Pra-pemrosesan)** - Data mentah yang telah dikumpulkan tidak dapat langsung dimasukkan ke dalam model pembelajaran mendalam karena perbedaan skala nilai yang sangat ekstrem. Oleh karena itu, data beban harian dinormalisasi menggunakan algoritma Min-Max *Scaling* untuk mentransformasikan nilai daya ke rentang skala standar [0, 1]. Setelah itu, data diolah menggunakan teknik *Sliding Window* sepanjang 60 jam (*sequence length* = 60) untuk mengekstrak fitur sekuensial yang menangkap pergerakan beban secara kronologis sebagai memori jangka pendek untuk umpan balik model *LSTM*.
3. **Stage 3: LSTM Predictive Model (Lapisan Pemodelan Prediktif)** - Lapisan ini merupakan otak dari sistem peramalan beban grid. Arsitektur model *LSTM* dua lapis dirancang untuk memproses sekuens input. Lapisan *LSTM* pertama (*LSTM Layer* 1) dikonfigurasi dengan 50 unit neuron dan mempertahankan sekuens keluaran (*return_sequences=True*). Untuk mencegah *overfitting*, disisipkan lapisan Dropout sebesar 20% sebelum masuk ke lapisan

LSTM kedua (*LSTM Layer* 2) yang juga memiliki 50 unit neuron dengan *output* berupa vektor tunggal (*return_sequences=False*). Vektor tersebut diteruskan ke *Dense Output Layer* dengan aktivasi linear untuk menghasilkan prediksi numerik kontinu beban grid listrik EVCS Area Solo Raya untuk hari esok (*Predicted H+1 Grid Load*).

4. **Stage 4: Action Signal Logic (Lapisan Logika Sinyal Tindakan)** - Keluaran berupa prediksi numerik dari tahap sebelumnya kemudian diolah secara cerdas menggunakan algoritma logika *threshold* keputusan (*Threshold Comparison Logic*). Sistem membandingkan nilai prediksi beban H+1 dengan batas ambang aman grid dan rata-rata penggunaan harian untuk menghasilkan sinyal visual praktis untuk pengguna, yaitu: (A) *CHARGE NOW (Low Load/Cost)*, ditandai dengan warna hijau, yang artinya prediksi beban esok hari kemungkinan berada di bawah rata-rata penggunaan harian dan tarif *ToU* berada pada fase minimum (*off-peak*); (B) *SKIP (Peak Load/Cost)*, ditandai dengan warna merah, yang artinya prediksi beban esok hari kemungkinan akan melebihi ambang batas aman atau tarif listrik berada pada skema beban puncak (*peak*); (C) *WAIT (Transitional State)*, ditandai dengan warna jingga, yang artinya prediksi beban esok hari kemungkinan akan berada pada fase transisi menuju stabil (*hold*) sehingga disarankan untuk menunda pengisian sementara waktu (menunggu stabil).



Gambar 1. Arsitektur Sistem Prediksi & Rekomendasi EVCS



Gambar 2. Diagram Alir Sistem Prediksi & Rekomendasi EVCS

2.3. Pra-pemrosesan Data (*Preprocessing*)

Arsitektur *deep learning LSTM* sangat sensitif terhadap perbedaan skala nilai masukan. Maka untuk menstabilkan data penggunaan daya harian (kWh) akan dinormalisasi menggunakan MinMax Scaler ke dalam rentang [0, 1] melalui persamaan:

$$X_{scaled} = (X - X_{min}) / (X_{max} - X_{min})$$

Setelah dinormalisasi, data runtun waktu diproses menggunakan teknik *Sliding Window*

sepanjang 60 hari (*sequence length = 60*). Dengan teknik ini, model dilatih untuk mempelajari pola konsumsi daya dari 60 hari sebelumnya (H-60 hingga hari H) sebagai basis fitur masukan untuk meramalkan nilai kebutuhan daya pada satu hari berikutnya (H+1).

Tabel 1 menyajikan contoh dataset historis penggunaan daya stasiun EVCS Area Solo Raya setelah disiapkan dan dinormalisasi untuk mempermudah pemahaman pembaca mengenai data runtun waktu.

Tabel 1. Contoh Data Historis EVCS Area Solo Raya 01 Januari 2021-01 Januari 2026

Tanggal	Konsumsi (kWh)	Tarif (Rp.)	Kategori Hari	Status Beban
01 Januari 2021	94.74	1450	Weekday	Medium
02 Januari 2021	72.89	1650	Weekend	Medium
~	~	~	~	~
27 Januari 2023	162.18	1450	Weekday	Peak
28 Januari 2023	141.73	1650	Weekend	Medium
29 Januari 2023	133.6	1650	Weekend	Low
~	~	~	~	~
31 Desember 2025	246.2	1450	Weekday	Peak
01 Januari 2026	240.88	1450	Weekday	Medium

2.4. Arsitektur Model *LSTM* dan Konfigurasi

Greff et al. (2017) merekomendasikan Model *LSTM* yang dibangun menggunakan modul *Keras* di bawah *framework TensorFlow* dikonfigurasi dengan spesifikasi *hyperparameter* sebagai berikut:

1. Lapisan 1: *LSTM Layer* dengan 50 neuron, *return_sequences=True* untuk

mempertahankan sekuens demi lapisan berikutnya.

2. Lapisan 2: *LSTM Layer* dengan 50 neuron, *return_sequences=False* untuk mengeluarkan output berupa vektor tunggal.

3. Regulasi: *Dropout Layer* bernilai 0.2 (20%) disisipkan sesudah setiap lapisan *LSTM* guna mencegah terjadinya *overfitting*.

4. Lapisan *Dense: Fully Connected Layer* dengan 25 unit neuron.
5. Lapisan *Output*: 1 unit neuron *Dense* dengan aktivasi linear untuk memproyeksikan nilai prediksi numerik kontinu H+1.
6. Optimasi: Adam *Optimizer* dengan *learning rate* 0.001 dan fungsi *loss Mean Squared Error (MSE)*.

2.5. Logika Sinyal Tindakan (*Action Signal*)

Proyeksi numerik beban daya pada hari esok (H+1) diterjemahkan oleh sistem menjadi rekomendasi keputusan pengisian baterai bagi pemilik EV melalui logika threshold adaptif:

- Sinyal *CHARGE NOW* dipicu jika prediksi beban grid esok hari berada di rentang rendah (Prediksi H+1 < Rata-rata Beban Harian) DAN kondisi tarif listrik berada pada skema *ToU minimum (off-peak)*.
- Sinyal *SKIP* dipicu jika proyeksi beban esok hari terindikasi sangat tinggi (Prediksi H+1 > Batas Atas Beban Aman) ATAU skema tarif berada pada tarif puncak (*peak hour rate*).
- Sinyal *WAIT* dipicu jika kondisi beban grid terdeteksi dalam fase transisi stabil (*Hold*).


Evaluasi kinerja model diukur menggunakan metrik *Root Mean Squared Error (RMSE)*, *Mean Absolute Percentage Error (MAPE)*, dan Koefisien Determinasi *R-Squared*.

3. HASIL DAN PEMBAHASAN

3.1. Pelatihan Model dan Hasil Prediksi

Proses pelatihan model *deep learning LSTM* dijalankan sebanyak 100 epochs dengan ukuran *batch (batch size)* sebesar 32. Kurva nilai *loss fungsi pelatihan (Training Loss)* dan validasi (*Validation Loss*) menunjukkan penurunan eksponensial yang stabil dan konvergen rapat tanpa adanya *divergensi lebar*. Hal ini mengindikasikan bahwa model terhindar dari bias tinggi (*underfitting*) maupun variansi berlebih (*overfitting*). Gambar 3 menunjukkan grafik perbandingan beban konsumsi daya aktual (*Test Set*) dengan hasil prediksi peramalan *LSTM* dengan rentang pengujian Oktober 2025–Januari 2026 membuktikan bahwa garis tren prediksi memiliki kemampuan tinggi dalam mengikuti pola historis aktual secara presisi.

Penilaian metrik performa model dievaluasi secara statistik dijelaskan pada Tabel 2.



Gambar 3. Grafik Perbandingan Konsumsi Daya Aktual vs Prediksi LSTM


Tabel 2. Evaluasi Kinerja Model Peramalan LSTM

Matrik Evaluasi	Nilai Performa	Keterangan Kualitatif
<i>RMSE</i>	0.5026 kW	Deviasi kuadrat rata-rata kesalahan sangat kecil
<i>MAPE</i>	2.34%	Akurasi tingkat peramalan dikategorikan "sangat akurat"
<i>R-Squared</i>	0.9852	Model mampu menjelaskan 98.52% variansi data aktual

3.2. Implementasi Sinyal Tindakan

Implementasi sinyal tindakan pengisian baterai menyajikan panduan praktis bagi pemilik EV. Sinyal visual *CHARGE NOW* (segitiga hijau) menandakan momentum pengisian optimal di mana beban grid rendah dan tarif listrik murah.

Sebaliknya, sinyal *SKIP* (segitiga merah) menginstruksikan pengguna untuk menghindari pengisian guna mencegah pengeluaran biaya tarif puncak yang mahal serta menjaga stabilitas operasional grid lokal. Sinyal *WAIT* (Sirkular Jingga) berfungsi sebagai penunda sementara selama fase transisi beban stabil.



Gambar 4. Visualisasi Distribusi Sinyal Tindakan Rekomendasi Pengisian EV

3.3. Pembahasan dan Analisis Efisiensi Finansial (*Backtesting*)

Keandalan fungsional model prediktif dan logika rekomendasi diuji secara mendalam menggunakan beberapa skenario simulasi *backtesting* finansial nyata sepanjang rentang operasional 2025–2026:

- 1. Skenario Akumulasi Pengisian Lembah (Kuartal I - 2025):** Sistem mendeteksi fase penurunan beban *grid* pada stasiun pengisian selama periode libur awal tahun. Kondisi ini memicu serangkaian sinyal *CHARGE NOW* pada zona tarif *off-peak* minimum, yang menghasilkan penurunan biaya energi sebesar 32,7%.

2. Skenario Penghindaran Beban Puncak (Kuartal IV - 2025): Saat beban daya di EVCS Area Solo Raya mencapai puncaknya pada akhir tahun, sistem secara dinamis memicu sinyal *SKIP* untuk mengalihkan antrian dari periode tarif beban puncak PLN. Mekanisme ini mampu mereduksi biaya energi operasional rata-rata bulanan sebesar 5%.

3. Pengelolaan Energi Jangka Panjang (Satu Tahun Penuh 2025-2026): Dalam simulasi jangka panjang, penerapan rekomendasi sinyal tindakan berbasis *Long Short-Term Memory* (LSTM) mampu mereduksi total biaya energi operasional sebesar Rp14.400.000. Strategi ini menghasilkan rasio penghematan biaya kumulatif mencapai 134,5% dibandingkan dengan pola pengisian acak konvensional."

4. KESIMPULAN

Berdasarkan hasil perancangan, implementasi, dan pengujian sistem komputasi yang telah dilaksanakan, dalam penelitian ini dapat ditarik beberapa kesimpulan:

1. Penerapan arsitektur *deep learning LSTM* untuk memprediksi fluktuasi konsumsi daya harian pada stasiun EVCS Area Solo Raya terbukti sangat akurat dalam memprediksi naik-turunnya konsumsi daya harian di EVCS wilayah Solo Raya, ditunjukkan oleh nilai metrik MAPE yang sangat kecil sebesar 2,34% dan R-Squared mencapai 0,9852. Artinya model mampu menjelaskan variasi data hingga 98,52%.
2. Penerapan regulisasi Dropout sebesar 20% pada model LSTM dua lapis terbukti tangguh dalam mencegah terjadinya kondisi overfitting serta berhasil menjaga stabilitas performa model, yang terlihat dari kurva loss pelatihan yang menurun secara konsisten dan stabil (konvergen).
3. Integrasi logika threshold keputusan terbukti andal dalam menyajikan keputusan pengisian baterai yang dinamis dan taktis mengikuti perubahan tarif listrik. Dari sisi ekonomi, sistem ini mampu menghasilkan rasio penghematan biaya operasional hingga 134,5% bagi pengguna kendaraan listrik jika dibandingkan dengan pola pengisian acak konvensional.

DAFTAR PUSTAKA

- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
- PT. PLN (Persero). (2024). Laporan Tahunan 2023: Akselerasi Transisi Energi Hijau Sektor Kelistrikan Nasional. Jakarta: PT. PLN.
- Putri, D. A., & Santoso, H. A. (2021). Analisis Faktor-Faktor yang Mempengaruhi Minat Penggunaan Kendaraan Listrik Pada Generasi Milenial. *Jurnal Ekonomi dan Bisnis Indonesia*, 35(2), 112-125.
- Rizki, A. M. (2022). Penerapan Deep Learning Menggunakan LSTM untuk Prediksi Beban Listrik Regional harian. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(10), 200-208.
- Zhang, Y. (2023). EV Charging Station Load Prediction Based on LSTM Neural Network. In *2023 IEEE 7th Information Technology and Mechatronics Engineering Conference (ITOEC)*, Chongqing, China, pp. 125-130.