

Electric Load Prediction at Sidoarjo Substation Using Long Short-Term Memory (LSTM) Method

[Prediksi Beban Listrik pada Gardu Induk Sidoarjo Menggunakan Metode Long Short-Term Memory (LSTM)]

Rachmad Maulid Santoni^{*}, Jamaaluddin, Shazana Dhiya Ayuni, Arief Wisaksono, Agus HF

Program Studi S1 Teknik Elektro, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Sidoarjo, Indonesia

Email Penulis Korespondensi: jamaaluddin@umsida.ac.id

Abstract. *Electric Load Prediction at Sidoarjo Substation Using Long Short-Term Memory (LSTM) Method. Load forecasting at substations supports operational planning and helps anticipate overload, yet substation loads are dynamic and nonlinear. This study applies an LSTM model to forecast short-term loads at 17 measurement points (transformer incomings and distribution feeders) at the Sidoarjo Substation using one year of operational data. Preprocessing included month conversion, session encoding, chronological sorting, Min-Max normalization, and a three-step sliding window. The model uses one 50-unit LSTM layer and a Dense output layer trained with the Adam optimizer and MSE loss; January-November data were used for training and December for testing. The Klurak Bali feeder achieved the lowest error (RMSE 5.50 A; MAPE 3.41%), while Heaven Land showed the highest (RMSE 40.13 A; MAPE 23.64%). LSTM models stable load patterns effectively, but accuracy declines for highly fluctuating loads.*

Keywords - artificial intelligence; deep learning; electric load forecasting; long short-term memory; Sidoarjo substation

Abstrak. *Prediksi beban listrik pada gardu induk mendukung perencanaan operasi dan antisipasi pembebanan berlebih, sedangkan beban listrik bersifat dinamis dan nonlinier. Penelitian ini menerapkan Long Short-Term Memory (LSTM) untuk memprediksi beban jangka pendek pada 17 titik pengukuran, terdiri atas incoming dan penyulang distribusi di Gardu Induk Sidoarjo, menggunakan 12.542 data operasional selama satu tahun. Pra-pemrosesan meliputi pengubahan format waktu, encoding sesi, pengurutan kronologis, normalisasi Min-Max, dan sliding window tiga langkah waktu. Model terdiri atas satu lapisan LSTM 50 unit dan Dense layer, dilatih dengan optimizer Adam dan loss MSE; data Januari-November digunakan untuk pelatihan dan Desember untuk pengujian. Penyulang Klurak Bali memperoleh galat terendah (RMSE 5,50 A; MAPE 3,41%), sedangkan Heaven Land tertinggi (RMSE 40,13 A; MAPE 23,64%). LSTM mampu memodelkan pola beban yang relatif stabil, tetapi akurasi menurun pada beban yang sangat berfluktuasi.*

Kata Kunci - gardu induk Sidoarjo; kecerdasan buatan; memori jangka pendek panjang; pembelajaran mendalam; prakiraan beban listrik

I. PENDAHULUAN

Energi listrik merupakan salah satu kebutuhan utama dalam mendukung aktivitas masyarakat, sektor industri, perdagangan, dan pelayanan publik [1]. Peningkatan kebutuhan energi listrik sejalan dengan perkembangan aktivitas ekonomi, infrastruktur, dan pemanfaatan teknologi kelistrikan. Pembangunan infrastruktur kelistrikan juga memiliki keterkaitan dengan pertumbuhan ekonomi karena ketersediaan listrik mendukung aktivitas produksi, distribusi, dan pelayanan masyarakat [2]. Dalam konteks sistem ketenagalistrikan nasional, perkembangan kebutuhan listrik dapat dilihat dari data statistik penyediaan dan pemanfaatan tenaga listrik yang dipublikasikan oleh PT PLN (Persero) [3]. Pada tingkat regional, kondisi operasional sistem distribusi di Jawa Timur juga menjadi bagian penting dalam menjaga kontinuitas penyaluran energi listrik kepada pelanggan [4]. Dengan demikian, peningkatan kebutuhan listrik perlu diimbangi dengan pengelolaan sistem tenaga listrik yang andal, terukur, dan mampu mengantisipasi perubahan beban.

Sistem tenaga listrik terdiri atas berbagai komponen yang saling terintegrasi mulai dari pembangkitan, transmisi, gardu induk, hingga jaringan distribusi. Transmisi tenaga listrik memiliki fungsi penting dalam menyalurkan energi listrik dari pusat pembangkitan menuju pusat beban dengan mempertimbangkan karakteristik, komponen, serta potensi gangguan pada sistem [5]. Konsumsi listrik di Indonesia juga dipengaruhi oleh berbagai faktor yang menyebabkan kebutuhan listrik mengalami perubahan dari waktu ke waktu [6]. Pada sisi distribusi, sistem kelistrikan memerlukan perangkat pengukuran dan pengendalian untuk memperoleh informasi mengenai kondisi operasi secara lebih akurat. Pemanfaatan teknologi pengukuran dan monitoring pada sistem kelistrikan telah berkembang, termasuk penggunaan sensor untuk memperoleh data arus, tegangan, dan daya secara lebih terintegrasi [7]. Informasi tersebut penting karena

perubahan beban yang tidak diantisipasi dapat meningkatkan risiko pembebanan berlebih pada peralatan dan memengaruhi keandalan operasi sistem.

Salah satu bagian penting dalam sistem tenaga listrik adalah gardu induk yang berfungsi sebagai titik penghubung dan pengaturan penyaluran energi listrik menuju jaringan distribusi. Beban pada gardu induk dapat berubah mengikuti pola konsumsi pelanggan, aktivitas industri, kondisi lingkungan, serta karakteristik waktu penggunaan listrik. Oleh karena itu, pemantauan dan analisis kondisi beban diperlukan untuk mendukung pengoperasian sistem secara optimal. Perkembangan metode *machine learning* dan *deep learning* memberikan alternatif untuk menganalisis data kelistrikan yang memiliki pola temporal dan kompleks [8]. Selain pendekatan berbasis kecerdasan buatan, metode statistik seperti *Autoregressive Integrated Moving Average* (ARIMA) juga telah digunakan dalam prediksi beban listrik jangka pendek [9]. Perbandingan antara pendekatan statistik dan pendekatan berbasis pembelajaran mesin menjadi penting karena karakteristik data beban listrik tidak selalu bersifat linier dan dapat mengalami perubahan pola dari waktu ke waktu.

Perkembangan teknologi kelistrikan tidak hanya ditunjukkan melalui metode prediksi, tetapi juga melalui penerapan teknologi pengukuran, monitoring, proteksi, dan pengendalian. Penerapan sistem manajemen energi dan perdagangan energi pada lingkungan yang memiliki ketidakpastian menunjukkan semakin pentingnya kemampuan sistem dalam mengelola perubahan kebutuhan energi [10]. Pada lingkungan *smart grid*, pendekatan *deep learning* telah digunakan untuk melakukan *short-term load forecasting* dengan mempertimbangkan pola konsumsi dan karakteristik kelompok pelanggan [11]. Perkembangan tersebut menunjukkan bahwa data kelistrikan yang tersedia dari sistem pengukuran dapat dimanfaatkan lebih lanjut sebagai dasar analisis dan prediksi.

Prediksi beban listrik merupakan permasalahan *time series* karena nilai beban pada suatu periode memiliki hubungan dengan nilai pada periode sebelumnya. Hubungan temporal tersebut menyebabkan metode prediksi perlu mampu mempelajari pola historis dan perubahan beban secara berurutan. Salah satu arsitektur yang dikembangkan untuk menangani permasalahan tersebut adalah *Long Short-Term Memory* (LSTM). LSTM diperkenalkan oleh Hochreiter dan Schmidhuber sebagai pengembangan *Recurrent Neural Network* (RNN) yang dirancang untuk mempelajari ketergantungan temporal dan mengatasi permasalahan keterbatasan pembelajaran pada hubungan jangka panjang [12]. Perkembangan metode prediksi beban berbasis kecerdasan buatan juga terlihat dari penerapan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) untuk prediksi beban listrik jangka pendek pada gardu induk 150 kV [13]. Penelitian tersebut menunjukkan bahwa data beban pada gardu induk dapat dimanfaatkan untuk membangun model prediksi berbasis pembelajaran komputasional.

Penerapan kecerdasan buatan dalam bidang kelistrikan terus berkembang seiring meningkatnya kebutuhan terhadap sistem monitoring dan pengendalian yang lebih adaptif. Berbagai penelitian juga menunjukkan pemanfaatan algoritma optimasi dan kecerdasan buatan pada sistem konversi energi, seperti optimasi DC-DC boost converter pada penggerak motor BLDC yang menggunakan sumber panel surya [14]. Pada sisi pengukuran, sensor PZEM-017 telah digunakan untuk memperoleh parameter arus, tegangan, dan daya pada instalasi panel surya serta mengirimkan data ke sistem pencatatan berbasis Google Spreadsheet dan smartphone [15]. Meskipun penerapannya berada pada konteks energi surya, perkembangan tersebut menunjukkan semakin luasnya pemanfaatan data kelistrikan secara digital. Dalam sistem *smart grid*, pemanfaatan data terukur menjadi semakin penting karena data historis dapat digunakan tidak hanya untuk monitoring, tetapi juga untuk analisis dan prediksi kondisi sistem.

Penelitian mengenai *short-term load forecasting* juga terus berkembang melalui penggunaan berbagai arsitektur *deep learning*. Pendekatan CNN-LSTM, misalnya, telah dikaji untuk meningkatkan kemampuan prediksi beban jangka pendek dengan menggabungkan kemampuan ekstraksi pola dan pembelajaran hubungan temporal [16]. Teknologi prediksi dan monitoring juga dapat diterapkan pada berbagai sistem kelistrikan lainnya, termasuk pemodelan hubungan tegangan dan arus pada sistem wireless power transfer [17]. Perkembangan tersebut memperlihatkan bahwa pemodelan data kelistrikan menggunakan pendekatan komputasional semakin luas dan dapat disesuaikan dengan karakteristik sistem yang dianalisis.

Pada sistem tenaga listrik berbasis energi terbarukan, analisis dan optimalisasi pengoperasian juga menjadi perhatian. Penelitian mengenai optimalisasi pengoperasian photovoltaic pada beban pompa air menunjukkan pentingnya pengelolaan daya agar pemanfaatan energi dapat dilakukan secara optimal [18]. Pengelolaan energi pada pembangkit tenaga surya juga berkaitan dengan kemampuan sistem dalam mengendalikan dan mempertahankan kondisi termal sehingga kinerja pembangkit dapat dipertahankan [19]. Selain pembangkitan, aspek pemeliharaan jaringan distribusi juga memerlukan dukungan teknologi untuk meningkatkan efektivitas pekerjaan lapangan. Optimalisasi penggunaan kendaraan *skylift* untuk pemeliharaan jaringan 20 kV tanpa padam menunjukkan adanya kebutuhan terhadap pengelolaan jaringan distribusi yang lebih efektif dan mendukung keandalan pelayanan listrik [20].

Perkembangan sistem monitoring dan otomasi juga menjadi bagian dari transformasi teknologi pada sistem kelistrikan. Penerapan sistem *object sorting conveyor* berbasis ESP-32 dan kamera menunjukkan pemanfaatan perangkat komputasi dan pengolahan citra untuk proses otomasi [21]. Dalam konteks pembelajaran pada data sekuensial, perkembangan LSTM selanjutnya diperkuat melalui mekanisme *forget gate* yang memungkinkan model menentukan informasi historis yang perlu dipertahankan atau dilupakan [22]. Mekanisme tersebut menjadi salah satu

dasar penting yang membuat LSTM sesuai untuk data yang memiliki ketergantungan temporal, termasuk data beban listrik.

Selain prediksi, keandalan sistem kelistrikan juga dipengaruhi oleh aspek proteksi dan kontinuitas pelayanan. Analisis pengamanan arus lebih pada *Miniature Circuit Breaker* (MCB) menunjukkan pentingnya sistem proteksi dalam menjaga peralatan listrik dari kondisi arus yang tidak normal [23]. Pada sisi kontinuitas suplai, perancangan *Automatic Transfer Switch* pada sistem pembangkit tenaga surya dan PLN menunjukkan penerapan sistem otomasi untuk mempertahankan ketersediaan pasokan energi listrik [24]. Aspek monitoring juga berkembang pada sistem infrastruktur dan peralatan, seperti penerapan *Internet of Things* (IoT) untuk pemantauan keamanan tanggul [25]. Walaupun berada pada objek yang berbeda, perkembangan IoT menunjukkan semakin luasnya pemanfaatan sistem akuisisi dan komunikasi data secara *real-time* yang dapat mendukung pengelolaan sistem berbasis data.

Pada bidang energi surya, penelitian mengenai sistem *dual-axis solar tracker* menunjukkan pemanfaatan sistem monitoring dan pengendalian untuk meningkatkan efektivitas penerimaan energi matahari [26]. Implementasi IoT juga diterapkan untuk monitoring kebocoran pada sistem *split duct air conditioner*, yang menunjukkan bahwa data sensor dapat dimanfaatkan untuk mendeteksi kondisi sistem secara lebih cepat [27]. Sementara itu, pengembangan sistem pengisian baterai sepeda listrik menggunakan panel surya memperlihatkan penerapan teknologi energi terbarukan dalam mendukung kebutuhan energi pada perangkat listrik modern [28]. Berbagai perkembangan tersebut memperlihatkan bahwa sistem kelistrikan modern semakin bergantung pada ketersediaan data, sistem monitoring, otomasi, serta metode analisis berbasis komputasi.

Berdasarkan perkembangan tersebut, kebutuhan terhadap metode yang mampu memanfaatkan data historis untuk memperoleh informasi mengenai kecenderungan beban menjadi semakin penting. LSTM memiliki karakteristik yang sesuai untuk pemodelan data sekuensial karena mampu mempertahankan informasi historis melalui *cell state* serta mengatur aliran informasi menggunakan *input gate*, *forget gate*, dan *output gate* [29]. Penerapan LSTM pada *load forecasting* juga didukung oleh berbagai penelitian yang menunjukkan kemampuan pendekatan *deep learning* dalam menangani pola konsumsi listrik yang kompleks [30], [31]. Dengan mempertimbangkan karakteristik tersebut, LSTM dapat digunakan sebagai pendekatan untuk memodelkan hubungan temporal pada data beban listrik di gardu induk.

Penelitian ini berfokus pada penerapan model LSTM untuk memprediksi beban listrik jangka pendek pada 17 titik pengukuran yang terdiri atas incoming dan penyulang distribusi di Gardu Induk Sidoarjo. Berbeda dengan pendekatan yang hanya mengevaluasi performa model secara agregat, penelitian ini mengevaluasi kinerja model secara individual pada setiap titik pengukuran. Evaluasi dilakukan menggunakan data pengujian bulan Desember dengan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Pendekatan evaluasi individual digunakan untuk memperoleh gambaran yang lebih spesifik mengenai kemampuan model dalam memprediksi karakteristik beban yang berbeda pada masing-masing titik pengukuran. Tujuan penelitian ini adalah menerapkan dan mengevaluasi model LSTM untuk memprediksi beban listrik jangka pendek pada 17 titik pengukuran di Gardu Induk Sidoarjo. Hasil penelitian diharapkan dapat memberikan informasi mengenai kinerja LSTM dalam prediksi beban listrik jangka pendek serta menjadi bahan pendukung dalam analisis dan pengelolaan beban pada Gardu Induk Sidoarjo.

II. METODE

A. Pendekatan penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode pemodelan deret waktu (*time series forecasting*). Pendekatan utama yang digunakan adalah *Deep Learning* dengan arsitektur *Long Short-Term Memory* (LSTM). LSTM termasuk dalam kelompok *Recurrent Neural Network* (RNN) yang dirancang untuk memproses data sekuensial dan mempertahankan informasi dari periode sebelumnya [12].

Data penelitian merupakan data sekunder berupa rekapitulasi pengukuran beban listrik pada Gardu Induk Sidoarjo selama satu tahun. Dataset terdiri atas 12.542 baris data yang mencakup 17 titik pengukuran. Setiap data memiliki informasi waktu dan nilai beban yang digunakan untuk membentuk urutan data sebelum diberikan kepada model LSTM.

Secara konseptual, kedudukan metode yang digunakan dalam penelitian ini adalah:

Artificial Intelligence → *Machine Learning* → *Deep Learning* → *Recurrent Neural Network* (RNN) → *Long Short-Term Memory* (LSTM)

LSTM dipilih karena karakteristik data beban listrik merupakan data berurutan yang memiliki hubungan temporal antara pengukuran sebelumnya dan pengukuran berikutnya.

B. Struktur dan mekanisme LSTM

Mekanisme LSTM terdiri atas tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*. Ketiga gerbang tersebut mengatur informasi yang akan dilupakan, disimpan, dan diteruskan pada setiap langkah waktu [12], [22].

Persamaan *forget gate* adalah:

$$f_t = \sigma(W_{xf} \times X_t + W_{hf} \times H_{t-1} + b_f) \quad (1)$$

Persamaan *input gate* adalah:

$$i_t = \sigma(W_{xi} \times X_t + W_{hi} \times H_{t-1} + b_i) \quad (2)$$

Nilai kandidat *cell state* dihitung menggunakan:

$$\tilde{C}_t = \tanh(W_{xc} \times X_t + W_{hc} \times H_{t-1} + b_c) \quad (3)$$

Selanjutnya, *cell state* diperbarui menggunakan:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (4)$$

Persamaan *output gate* adalah:

$$o_t = \sigma(W_{xo} \times X_t + W_{ho} \times H_{t-1} + b_o) \quad (5)$$

Sedangkan *hidden state* dihitung dengan:

$$H_t = o_t \odot \tanh(C_t) \quad (6)$$

Keterangan: X_t merupakan data masukan pada waktu t , H_t merupakan *hidden state*, C_t merupakan *cell state*, W merupakan bobot jaringan, b merupakan bias, σ merupakan fungsi aktivasi sigmoid, $\tanh$ merupakan fungsi aktivasi hiperbolik, dan $\odot$ menunjukkan perkalian elemen demi elemen.

C. Pengumpulan dan pra-pemrosesan data

Data yang digunakan merupakan data rekapitulasi beban listrik selama periode Januari sampai Desember. Proses pengolahan data dilakukan menggunakan Python dengan pustaka TensorFlow/Keras, Pandas, NumPy, dan Scikit-Learn.

Tahapan pra-pemrosesan data dilakukan sebagai berikut:

- Pemetaan bulan, yaitu mengubah informasi nama bulan Januari sampai Desember menjadi nilai numerik 1 sampai 12.
- Encoding* sesi, yaitu mengubah informasi sesi pengukuran menjadi nilai numerik sehingga urutan data dapat diproses secara komputasional.
- Pengurutan kronologis, yaitu mengurutkan data berdasarkan penyulang, bulan, tanggal, dan sesi pengukuran.
- Normalisasi, yaitu mengubah nilai beban ke dalam rentang 0 sampai 1 menggunakan metode *Min-Max Scaling*.
- Pembentukan *sequence*, yaitu membentuk data masukan menggunakan metode *sliding window* dengan *time step* sebesar 3.

Normalisasi *Min-Max* digunakan untuk mengubah nilai data ke dalam rentang 0 sampai 1. Persamaannya adalah:

$$X_{\text{scaled}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

dengan X merupakan nilai aktual, $X_{\min}$ merupakan nilai minimum, dan $X_{\max}$ merupakan nilai maksimum pada data yang digunakan dalam proses normalisasi.

Data hasil normalisasi kemudian diubah menjadi bentuk sekuensial menggunakan metode *sliding window*. Model menggunakan tiga pengamatan sebelumnya untuk memprediksi satu pengamatan berikutnya.

Bentuk input dan target dapat dituliskan sebagai:

$$[X_{t-2}, X_{t-1}, X_t] \rightarrow X_{t+1} \quad (8)$$

Dengan demikian, model tidak hanya menggunakan satu nilai historis, tetapi memanfaatkan tiga urutan pengamatan sebelumnya sebagai informasi masukan dalam proses prediksi.

D. Pembagian data *training* dan *testing*

Pembagian data dilakukan berdasarkan urutan waktu untuk mencegah penggunaan informasi masa depan pada proses pelatihan. Data bulan Januari sampai November digunakan sebagai data *training*, sedangkan data bulan Desember digunakan sebagai data *testing*.

Pembagian tersebut memungkinkan model dilatih menggunakan data historis dan kemudian dievaluasi menggunakan periode yang tidak digunakan selama proses pelatihan. Dengan pendekatan ini, performa model dapat diamati pada kondisi data yang berbeda dari data pelatihan.

E. Arsitektur model *Deep Learning LSTM*

Model yang digunakan merupakan jaringan *Deep Learning* dengan satu lapisan LSTM dan satu lapisan *Dense*. Lapisan LSTM terdiri atas 50 unit neuron dengan input berbentuk tiga *time step* dan satu fitur. Lapisan *Dense* memiliki satu neuron keluaran karena target prediksi berupa satu nilai beban listrik kontinu. Konfigurasi parameter model ditunjukkan pada Tabel 1.

Tabel 1. Parameter konfigurasi model LSTM

No	Parameter	Konfigurasi
1	Arsitektur	LSTM
2	Jumlah LSTM layer	1 layer
3	Jumlah neuron LSTM	50 unit
4	Time step	3
5	Output layer	Dense
6	Jumlah neuron output	1 neuron
7	Fungsi aktivasi LSTM	tanh
8	Fungsi loss	Mean Squared Error (MSE)
9	Optimizer	Adam
10	Learning rate	0,001
11	Epoch	30
12	Batch size	16

Model diimplementasikan menggunakan TensorFlow/Keras. Parameter tersebut digunakan secara konsisten pada proses pelatihan seluruh titik pengukuran sehingga hasil evaluasi antarpengulangan dapat dibandingkan.

F. Proses pelatihan dan prediksi

Proses pelatihan dimulai dengan memberikan *sequence* data hasil normalisasi kepada model LSTM. Model kemudian memperbarui bobot berdasarkan nilai kesalahan antara keluaran prediksi dan target aktual. Proses tersebut dilakukan secara iteratif selama 30 *epoch* menggunakan *optimizer* Adam dan fungsi loss *Mean Squared Error*.

Setelah proses pelatihan selesai, model digunakan untuk menghasilkan prediksi pada data bulan Desember. Hasil prediksi yang masih berada pada skala normalisasi kemudian dikembalikan ke satuan aktual menggunakan proses *inverse transformation*. Selanjutnya, hasil prediksi dibandingkan dengan data aktual untuk memperoleh nilai RMSE dan MAPE.

Alur penelitian secara keseluruhan dapat diringkas sebagai berikut:

Data Historis → *Preprocessing* → Normalisasi → *Sliding Window* → Pembagian *Training/Testing* → LSTM 50 Neuron → *Dense* 1 Neuron → Prediksi → *Inverse Transform* → Evaluasi

G. Evaluasi model

Kinerja model dievaluasi menggunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). RMSE menunjukkan besarnya rata-rata kesalahan prediksi dalam satuan yang sama dengan data beban, sedangkan MAPE menunjukkan rata-rata kesalahan dalam bentuk persentase.

Persamaan RMSE adalah:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

Persamaan MAPE adalah:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (10)$$

dengan y_i merupakan nilai aktual, $\hat{y}_i$ merupakan nilai hasil prediksi, dan n merupakan jumlah data pengujian.

Semakin kecil nilai RMSE dan MAPE, semakin kecil kesalahan prediksi yang dihasilkan oleh model terhadap data aktual.

III. HASIL DAN PEMBAHASAN

Model LSTM dievaluasi secara individual pada 17 titik pengukuran di Gardu Induk Sidoarjo menggunakan data pengujian bulan Desember. Hasil evaluasi terdiri atas rata-rata beban aktual, RMSE, MAPE, dan kategori kinerja berdasarkan hasil kesalahan prediksi. Hasil evaluasi disajikan pada Tabel 2.

Tabel 2. Hasil evaluasi prediksi beban listrik bulan Desember per penyulang

No	Titik pengukuran	Rata-rata beban aktual (A)	RMSE (A)	MAPE (%)	Kategori
1	Klurak Bali	121,76	5,50	3,41	Sangat Tinggi
2	Tenggulunan	144,02	11,11	4,91	Sangat Tinggi
3	Incoming 1	1.271,06	116,50	7,12	Tinggi
4	Kepadangan	104,70	13,71	9,49	Tinggi
5	Mutiara Citra Asri	149,95	16,20	9,52	Tinggi
6	Graha Kota	198,27	24,92	10,57	Baik
7	Candi Pari	139,83	20,09	10,76	Baik
8	Gempolsari	181,41	23,20	11,25	Baik
9	Bumi Mulyo	181,56	23,92	11,42	Baik
10	Incoming 2	1.239,97	171,02	12,19	Baik
11	Sumokali	193,11	30,84	13,29	Cukup Baik
12	Jiken	146,68	25,16	15,29	Cukup Baik
13	Ecco	157,77	29,18	15,89	Cukup Baik
14	Permisan	174,90	33,92	15,96	Cukup Baik
15	Umsida	131,77	28,73	17,52	Cukup Baik
16	Jimbaran	210,40	52,43	18,91	Cukup Baik
17	Heaven Land	148,52	40,13	23,64	Fluktuatif/Sedang

A. Performa prediksi pada penyulang dengan error rendah

Hasil pengujian menunjukkan bahwa Penyulang Klurak Bali menghasilkan performa prediksi terbaik dengan RMSE sebesar 5,50 A dan MAPE sebesar 3,41%. Nilai tersebut menunjukkan bahwa perbedaan antara hasil prediksi dan beban aktual relatif kecil pada periode pengujian. Penyulang Tenggulunan juga menghasilkan kinerja yang baik dengan RMSE sebesar 11,11 A dan MAPE sebesar 4,91%.

Hasil tersebut menunjukkan bahwa model LSTM dapat menangkap pola temporal dengan lebih baik pada data yang memiliki karakteristik relatif stabil atau memiliki pola yang berulang. Kondisi tersebut sesuai dengan karakteristik LSTM yang memanfaatkan informasi dari beberapa periode sebelumnya untuk menghasilkan prediksi periode berikutnya.

Pada Penyulang Klurak Bali, kurva prediksi menunjukkan kecenderungan mengikuti perubahan kurva beban aktual. Hal tersebut mengindikasikan bahwa informasi dari tiga periode sebelumnya cukup membantu model dalam memperkirakan nilai pada periode berikutnya. Hasil evaluasi grafik penyulang Klurak Bali menunjukkan RMSE sebesar 5,50 A dan MAPE sebesar 3,41%.

B. Performa prediksi pada incoming gardu induk

Pada dua titik pengukuran utama, yaitu Incoming 1 dan Incoming 2, nilai beban rata-rata jauh lebih besar dibandingkan sebagian besar penyulang distribusi. Incoming 1 memiliki rata-rata beban aktual sebesar 1.271,06 A dengan RMSE sebesar 116,50 A dan MAPE sebesar 7,12%. Sementara itu, Incoming 2 memiliki rata-rata beban sebesar 1.239,97 A dengan RMSE sebesar 171,02 A dan MAPE sebesar 12,19%.

Meskipun nilai RMSE dalam satuan ampere relatif besar, interpretasi kesalahan juga perlu mempertimbangkan skala beban. MAPE sebesar 7,12% pada Incoming 1 menunjukkan kesalahan relatif yang lebih rendah dibandingkan beberapa penyulang dengan beban lebih kecil. Incoming 2 menghasilkan MAPE yang lebih tinggi, yaitu 12,19%, yang menunjukkan adanya perbedaan kemampuan model dalam mengikuti pola perubahan beban pada kedua incoming tersebut.

Hasil ini menunjukkan bahwa evaluasi menggunakan MAPE penting untuk melengkapi RMSE, khususnya ketika objek yang dibandingkan memiliki skala beban yang berbeda. Data hasil evaluasi Incoming 1 dan Incoming 2 menunjukkan nilai masing-masing 7,12% dan 12,19%.

C. Performa pada penyulang dengan fluktuasi tinggi

Kinerja model menurun pada penyulang yang memiliki perubahan beban lebih tinggi. Penyulang Heaven Land menghasilkan RMSE sebesar 40,13 A dan MAPE sebesar 23,64%, sedangkan Penyulang Jimbaran menghasilkan RMSE sebesar 52,43 A dan MAPE sebesar 18,91%.

Perbedaan tersebut menunjukkan bahwa LSTM tidak selalu menghasilkan tingkat kesalahan yang sama pada seluruh karakteristik beban. Ketika perubahan beban bersifat tajam dan tidak mengikuti pola temporal yang konsisten,

informasi historis dari tiga periode sebelumnya menjadi kurang representatif untuk memperkirakan perubahan berikutnya.

Pada data bulan Desember, terdapat perubahan beban yang tajam pada beberapa sesi pengukuran di Penyulang Heaven Land dan Jimbaran. Kondisi tersebut dapat menyebabkan perbedaan yang lebih besar antara nilai aktual dan prediksi.

Dengan demikian, tingginya nilai MAPE pada kedua penyulang tersebut tidak semata-mata menunjukkan kelemahan algoritma LSTM, tetapi juga mencerminkan kompleksitas karakteristik data yang digunakan. Peningkatan kinerja pada kondisi tersebut dapat menjadi peluang pengembangan penelitian berikutnya melalui penggunaan fitur tambahan, seperti informasi hari, jam, hari kerja/libur, cuaca, atau metode *feature engineering* lainnya.

D. Analisis keseluruhan hasil

Berdasarkan Tabel 2, hasil prediksi menunjukkan variasi kinerja antarpemulung. Dua pemulung menghasilkan MAPE di bawah 5%, yaitu Klurak Bali sebesar 3,41% dan Tenggulungan sebesar 4,91%. Tujuh titik pengukuran berikutnya menghasilkan MAPE antara 7,12% sampai 11,42%, sedangkan beberapa pemulung lainnya memiliki MAPE di atas 15%.

Variasi tersebut menunjukkan bahwa karakteristik beban merupakan salah satu faktor penting yang memengaruhi performa prediksi. Model yang sama dapat menghasilkan tingkat kesalahan yang berbeda ketika diterapkan pada data dengan pola temporal yang berbeda. Oleh sebab itu, evaluasi individual pada setiap pemulung diperlukan agar hasil prediksi tidak hanya dilihat berdasarkan nilai rata-rata seluruh sistem.

Secara keseluruhan, hasil penelitian menunjukkan bahwa pendekatan *Deep Learning* dengan arsitektur LSTM memiliki kemampuan untuk memodelkan pola temporal beban listrik pada Gardu Induk Sidoarjo. Namun, kemampuan model lebih baik pada data dengan pola relatif stabil dibandingkan data yang mengalami perubahan ekstrem.

E. Implikasi hasil prediksi

Hasil prediksi beban listrik dapat digunakan sebagai salah satu informasi pendukung dalam pengelolaan operasi sistem tenaga listrik. Prediksi yang memiliki tingkat kesalahan relatif rendah dapat membantu operator memperoleh estimasi beban pada periode berikutnya sehingga perubahan kebutuhan beban dapat diantisipasi lebih awal.

Pada tingkat gardu induk, informasi prediksi dapat mendukung pemantauan kecenderungan pembebanan pada incoming maupun pemulung distribusi. Pemulung dengan kecenderungan peningkatan beban dapat menjadi prioritas dalam pemantauan operasional, sedangkan pemulung dengan pola yang lebih stabil dapat diprediksi dengan tingkat ketidakpastian yang relatif lebih rendah.

Penerapan lebih lanjut dapat diarahkan pada integrasi hasil prediksi ke dalam sistem monitoring atau *smart grid*. Model prediksi dapat ditempatkan sebagai salah satu komponen analitik yang menerima data historis secara berkala dan menghasilkan estimasi beban untuk periode berikutnya.

Meskipun demikian, hasil prediksi LSTM sebaiknya digunakan sebagai informasi pendukung dan bukan sebagai satu-satunya dasar pengambilan keputusan operasional. Kondisi aktual jaringan, kapasitas peralatan, gangguan, perubahan konfigurasi jaringan, dan kondisi operasi lainnya tetap perlu dipertimbangkan oleh operator.

IV. SIMPULAN

Penelitian ini menerapkan pendekatan *Deep Learning* dengan arsitektur *Long Short-Term Memory* (LSTM) untuk memprediksi beban listrik jangka pendek pada 17 titik pengukuran yang terdiri atas incoming dan pemulung distribusi di Gardu Induk Sidoarjo. Data Januari sampai November digunakan untuk proses pelatihan, sedangkan data bulan Desember digunakan sebagai data pengujian. Model menggunakan tiga data historis sebagai input, satu lapisan LSTM dengan 50 unit neuron, satu lapisan *Dense* dengan satu neuron keluaran, *optimizer* Adam dengan *learning rate* 0,001, 30 *epoch*, dan *batch size* 16.

Hasil evaluasi menunjukkan bahwa performa model berbeda pada setiap pemulung. Kinerja terbaik diperoleh pada Penyulang Klurak Bali dengan RMSE sebesar 5,50 A dan MAPE sebesar 3,41%, diikuti Penyulang Tenggulungan dengan RMSE sebesar 11,11 A dan MAPE sebesar 4,91%. Sementara itu, error tertinggi diperoleh pada Penyulang Heaven Land dengan RMSE sebesar 40,13 A dan MAPE sebesar 23,64%.

Hasil tersebut menunjukkan bahwa LSTM mampu memberikan prediksi yang relatif baik pada pemulung dengan pola beban yang lebih stabil. Namun, performanya menurun pada data dengan fluktuasi yang tinggi dan perubahan beban yang tidak konsisten. Oleh karena itu, karakteristik data masing-masing pemulung perlu dipertimbangkan dalam penerapan sistem prediksi beban berbasis LSTM.

Penelitian selanjutnya dapat mengembangkan model dengan menambahkan variabel eksternal yang berpotensi memengaruhi beban listrik, seperti jam pengukuran, hari kerja dan hari libur, kondisi cuaca, temperatur, serta karakteristik konsumsi pelanggan. Selain itu, performa LSTM dapat dibandingkan dengan arsitektur lain seperti GRU, CNN-LSTM, atau model *Transformer* untuk mengetahui pendekatan yang lebih sesuai terhadap karakteristik beban masing-masing pemulung.

Pengembangan berikutnya juga dapat diarahkan pada sistem prediksi secara *real-time* yang terintegrasi dengan sistem monitoring Gardu Induk sehingga hasil prediksi dapat diperbarui secara otomatis berdasarkan data pengukuran terbaru.

REFERENSI

- [1] M. M. Nurmansyah and F. Apriani, “Layanan Publik Penyediaan Listrik oleh PT. PLN (Persero) di,” vol. 2, no. 1, pp. 247–255, 2024.
- [2] L. Hasanah, “Pengaruh Pembangunan Infrastruktur Jalan, Listrik, dan Air terhadap Pertumbuhan Ekonomi di Kota Surabaya,” 2024.
- [3] PT PLN (Persero), *Statistik PLN 2022*, No. 03001. Jakarta: PT PLN (Persero), 2022.
- [4] PT PLN (Persero) UID Jawa Timur, *Laporan Kinerja Operasional Distribusi Listrik Jawa Timur 2023*. Surabaya: PLN UID Jawa Timur, 2023.
- [5] A. Sumiyati *et al.*, “Konsep Dasar Transmisi Tenaga Listrik: Klasifikasi, Komponen Serta Gangguannya,” vol. 11, no. 2, pp. 612–617, 2024.
- [6] S. Johan, A. M. Ginting, and P. Studi, “Determinan Konsumsi Listrik di Indonesia,” *Jurnal Ekonomi dan Bisnis*, vol. 30, no. 1, pp. 106–117, 2022.
- [7] P. Rojanavas, A. Jitpattanakul, and S. Mekruksavanich, “Comparative Analysis of LSTM-Based Deep Learning Models for HAR Using Smartphone Sensor,” in *2021 Joint 6th International Conference on Digital Arts, Media and Technology with 4th ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunication Engineering (ECTI DAMT & NCON 2021)*, 2021, pp. 269–272.
- [8] A. Moradzadeh, A. Mansour-Saatloo, M. Nazari-Heris, B. Mohammadi-Ivatloo, and S. Asadi, “Introduction and Literature Review of the Application of Machine Learning/Deep Learning to Load Forecasting in Power System,” in *Power Systems*, 2021, pp. 119–135.
- [9] R. Hakim, D. Despa, and L. Hakim, “Prediksi Beban Listrik Jangka Pendek Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA),” *Electrician*, vol. 14, no. 1, pp. 26–33, 2020.
- [10] S. S. Khan, S. Ahmad, and M. Naeem, “On-grid Joint Energy Management and Trading in Uncertain Environment,” *Applied Energy*, vol. 330, p. 120318, 2023.
- [11] D. Syed *et al.*, “Deep Learning-Based Short-Term Load Forecasting Approach in Smart Grid with Clustering and Consumption Pattern Recognition,” *IEEE Access*, vol. 9, pp. 54992–55008, 2021.
- [12] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [13] N. Aiza, I. M. A. Nnarth, I. M. Ginarsa, A. B. Muljono, A. Zainuddin, and S. Sultan, “Implementasi Adaptive Neuro-Fuzzy Inference System untuk Prediksi Beban Listrik Jangka Pendek di Gardu Induk 150 kV Tanjung,” *Jurnal Fokus Elektroda*, vol. 10, no. 2, pp. 35–40, 2025.
- [14] I. Anshory *et al.*, “Optimization DC-DC Boost Converter of BLDC Motor Drive by Solar Panel Using PID and Firefly Algorithm,” *Results in Engineering*, vol. 21, p. 101727, 2024.
- [15] A. M. 'Aafi, J. Jamaaluddin, and I. Anshory, “Implementasi Sensor PZEM-017 untuk Monitoring Arus, Tegangan dan Daya pada Instalasi Panel Surya dengan Sistem Data Logger Menggunakan Google Spreadsheet dan Smartphone,” *Seminar Nasional Teknik Elektro (SNESTIK)*, 2022, pp. 191–196.
- [16] K. Ullah *et al.*, “Short-Term Load Forecasting: A Comprehensive Review and Simulation Study with CNN-LSTM Hybrids Approach,” *IEEE Access*, vol. 12, pp. 111858–111881, 2024.
- [17] S. D. Ayuni and S. Syahririni, “Empirical Regression-Based Model for Predicting Voltage and Current in a Household Wireless Power Transfer System,” *IJINS*, vol. 26, no. 4, pp. 1–7, 2025.
- [18] J. Jamaaluddin, A. A. Tsaalits, I. Anshory, and D. Bs., “Analisa Optimalisasi Pengoperasian Photovoltaic pada Beban Pompa Air dengan Daya 350,” *Jurnal REEC*, vol. 6, no. 1, pp. 1–8, 2026.
- [19] J. Jamaaluddin *et al.*, “Heat Transfer Management of Solar Power Plant for Dryer,” *International Journal of Renewable Energy*, vol. 12, pp. 195–203, 2024.
- [20] M. Abdul, A. Al, S. D. Ayuni, A. H. Falah, and I. Anshory, “Optimalisasi Mobil Skyliift terhadap Kontribusi Pemeliharaan Jaringan 20 kV Tanpa Padam di PT PLN (Persero) UP3 Sidoarjo,” *Jurnal Fokus Elektroda*, vol. 11, no. 2, pp. 83–88, 2026.
- [21] I. Sulistiyowati, H. M. Ichsan, and I. Anshory, “Object Sorting Conveyor with Detection Color Using ESP-32 Camera Python Based on OpenCV,” *Journal of Robotics and Control*, vol. 9, no. 1, pp. 61–67, 2024.
- [22] F. A. Gers and F. Cummins, “Learning to Forget: Continual Prediction with LSTM,” *Neural Computation*, vol. 12, no. 10, pp. 2451–2471, 2000.

- [23] J. Jamaaluddin, I. Anshory, and S. D. Ayuni, "Analysis of Overcurrent Safety in Miniature Circuit Breaker with Alternating Current," *Journal of Electrical Technology UMY*, vol. 5, no. 2, pp. 68–73, 2021.
- [24] J. Jamaaluddin, S. D. Ayuni, and I. A. S. Wulandari, "Design of Automatic Transfer Switch System Solar Power Plant–PLN," *Journal of Electrical Technology UMY*, vol. 7, no. 2, pp. 57–64, 2023.
- [25] S. D. Ayuni, S. Syahririni, and J. Jamaaluddin, "Lapindo Embankment Security Monitoring System Based on IoT," *Elinvo (Electronics, Informatics, and Vocational Education)*, vol. 6, no. 1, pp. 40–48, 2021.
- [26] I. Anshory, J. Jamaaluddin, A. Fahrudin, A. Fudholi, and Y. Radiansah, "Monitoring Solar Heat Intensity of Dual Axis Solar Tracker Control System: New Approach," *Case Studies in Thermal Engineering*, vol. 53, p. 103791, 2024.
- [27] E. A. S. Aji, J. Jamaaluddin, A. Ahfas, and S. D. Ayuni, "Leak Monitoring in Split Duct Air Conditioner Based on Internet of Things," *JEEE-U (Journal of Electrical and Electronic Engineering-UMSIDA)*, vol. 7, no. 2, pp. 176–187, 2023.
- [28] M. R. Pratama, J. Jamaaluddin, and I. Sulistiyowati, "Electric Bicycle Battery Charging System Design Using Solar Panel," *JEEE-U (Journal of Electrical and Electronic Engineering-UMSIDA)*, vol. 8, no. 2, pp. 1–8, 2024.
- [29] S. D. Ayuni and S. Syahririni, "Empirical Regression-Based Model for Predicting Voltage and Current in a Household Wireless Power Transfer System," *IJINS*, vol. 26, no. 4, pp. 1–7, 2025.
- [30] A. Wisaksono, "Sistem Monitoring dan Analisis Kinerja Jaringan Listrik pada Industri," *Jurnal Teknik Elektro*, vol. 12, no. 1, pp. 45–52, 2023.
- [31] A. Wisaksono and Y. Purwanti, "Design of Monitoring and Control of Energy Use in Multi-storey Buildings based on IoT," *JEEE-U (Journal of Electrical and Electronic Engineering-UMSIDA)*, vol. 4, no. 2, pp. 128–135, 2020.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.