

## **Prediksi Konsumsi Energi Listrik Gedung Kampus Menggunakan Long Short-Term Memory (LSTM) Berbasis Data IoT pada Sistem Smart Building**

**Dandi Yohananda Saputra Utama<sup>1</sup>, Mustika Ningrum<sup>2</sup>, Cahya Ade Ningrum<sup>3</sup>**

<sup>123</sup> Universitas Indonesia Mandiri

[dandiyohanandasaputra@uimandiri.ac.id](mailto:dandiyohanandasaputra@uimandiri.ac.id), [mustikaningrum@uimandiri.ac.id](mailto:mustikaningrum@uimandiri.ac.id), [cahyaadeningrum@uimandiri.ac.id](mailto:cahyaadeningrum@uimandiri.ac.id)

### **Abstrak**

Gedung kampus merupakan salah satu fasilitas dengan tingkat konsumsi energi listrik yang tinggi dan bersifat dinamis mengikuti pola aktivitas akademik. Pengelolaan energi yang belum optimal dapat menyebabkan pemborosan energi dan peningkatan biaya operasional. Penelitian ini bertujuan untuk membangun model prediksi konsumsi energi listrik gedung kampus menggunakan metode Long Short-Term Memory (LSTM) berbasis data Internet of Things (IoT) dalam kerangka sistem Smart Building. Data konsumsi energi diperoleh dari sistem monitoring IoT dengan interval pencatatan setiap 5 menit dan berjumlah sekitar 10.000 record. Tahapan penelitian meliputi pra-pemrosesan data, normalisasi menggunakan Min-Max Normalization, pembagian dataset menjadi data pelatihan (70%), validasi (15%), dan pengujian (15%), serta perancangan dan pelatihan model LSTM. Evaluasi performa model dilakukan menggunakan metrik Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE). Hasil penelitian menunjukkan bahwa model LSTM mampu memprediksi konsumsi energi listrik dengan tingkat kesalahan yang rendah, yaitu MAE sebesar 0,018, MSE sebesar 0,00052, dan RMSE sebesar 0,0228. Model yang diusulkan mampu mengikuti pola konsumsi energi listrik yang fluktuatif dan nonlinier dengan baik. Integrasi IoT dan LSTM dalam penelitian ini memberikan kontribusi dalam mendukung manajemen energi berbasis data pada sistem Smart Building yang lebih efisien dan berkelanjutan.

Kata kunci: Smart Building, Internet of Things, LSTM, Prediksi Energi, Konsumsi Energi Listrik

### **Abstract**

Campus buildings are facilities with relatively high and dynamic electricity consumption levels influenced by academic activities. Inefficient energy management may lead to energy waste and increased operational costs. This study aims to develop an electricity consumption prediction model for campus buildings using a Long Short-Term Memory (LSTM) method based on Internet of Things (IoT) data within a Smart Building framework. Energy consumption data were collected from an IoT-based monitoring system at 5-minute intervals, resulting in approximately 10,000 records. The research stages included data preprocessing, normalization using Min-Max Normalization, dataset splitting into training (70%), validation (15%), and testing (15%) sets, as well as LSTM model design and training. Model performance was evaluated using Mean Absolute Error (MAE), Mean Squared Error (MSE), and Root Mean

Squared Error (RMSE). The results indicate that the LSTM model achieved low prediction errors, with MAE of 0.018, MSE of 0.00052, and RMSE of 0.0228. The proposed model effectively captured nonlinear and fluctuating electricity consumption patterns. The integration of IoT and LSTM in this study contributes to data-driven energy management in Smart Building systems, supporting more efficient and sustainable building operations.

Keywords: Smart Building, Internet of Things, LSTM, Energy Forecasting, Electricity Consumption

## 1. Pendahuluan

Gedung kampus merupakan salah satu fasilitas publik dengan tingkat konsumsi energi listrik yang relatif tinggi. Energi listrik digunakan untuk mendukung berbagai aktivitas akademik dan non-akademik, seperti penerangan, sistem pendingin ruangan, peralatan laboratorium, serta infrastruktur teknologi informasi. Peningkatan aktivitas dan jumlah pengguna gedung kampus secara langsung berdampak pada meningkatnya kebutuhan energi listrik, yang apabila tidak dikelola dengan baik dapat menyebabkan pemborosan energi dan tingginya biaya operasional (Pérez-Lombard et al., 2008).

Pengelolaan energi listrik pada gedung kampus menghadapi tantangan utama berupa efisiensi energi dan manajemen beban listrik. Pola konsumsi energi bersifat dinamis dan dipengaruhi oleh aktivitas harian, mingguan, hingga musiman, seperti jadwal perkuliahan dan kegiatan akademik lainnya. Fluktuasi beban listrik yang tidak terprediksi dengan baik dapat mengurangi efisiensi sistem kelistrikan dan menyulitkan perencanaan energi secara optimal (Hong et al., 2019).

Pada umumnya, sistem pengelolaan energi listrik konvensional masih bersifat reaktif dan hanya berfokus pada pemantauan konsumsi energi tanpa kemampuan prediksi yang akurat. Ketidakmampuan sistem tersebut dalam memprediksi konsumsi energi listrik menyebabkan pengambilan keputusan dilakukan setelah terjadi peningkatan beban, sehingga potensi efisiensi energi belum dapat dimanfaatkan secara maksimal (Ahmad et al., 2014).

Konsep *Smart Building* hadir sebagai solusi dengan memanfaatkan teknologi digital untuk meningkatkan efisiensi pengelolaan gedung. Salah satu teknologi kunci dalam implementasi *Smart Building* adalah Internet of Things (IoT), yang memungkinkan pengumpulan data konsumsi energi listrik secara real-time melalui sensor dan perangkat pintar yang terintegrasi. Data yang dihasilkan oleh sistem IoT bersifat deret waktu (*time series*) dan dapat digunakan untuk monitoring, analisis, serta pengambilan keputusan berbasis data (Gubbi et al., 2013).

Untuk menganalisis dan memprediksi konsumsi energi listrik yang bersifat deret waktu, diperlukan metode yang mampu menangkap pola kompleks dan ketergantungan jangka panjang. *Long Short-Term Memory* (LSTM), sebagai pengembangan dari *Recurrent Neural Network* (RNN), memiliki kemampuan yang baik dalam memodelkan data deret waktu dan telah banyak digunakan dalam penelitian prediksi konsumsi energi listrik (Hochreiter & Schmidhuber, 1997; Marino et al., 2016). Oleh karena itu, penelitian ini mengusulkan penggunaan model LSTM berbasis data IoT untuk memprediksi konsumsi energi listrik pada gedung kampus.

Penelitian ini bertujuan untuk membangun model prediksi konsumsi energi listrik menggunakan LSTM serta menganalisis performanya berdasarkan data yang diperoleh dari sistem IoT. Integrasi IoT dan LSTM diharapkan dapat menghasilkan model prediksi yang akurat dan andal, sehingga dapat digunakan sebagai dasar pengambilan keputusan dalam manajemen energi gedung kampus dan mendukung implementasi sistem *Smart Building* yang efisien dan berkelanjutan.

## **2. Tinjauan Pustaka**

### **2.1 Smart Building dan Manajemen Energi**

*Smart Building* merupakan konsep pengelolaan gedung yang memanfaatkan teknologi informasi dan komunikasi untuk meningkatkan efisiensi energi, kenyamanan pengguna, serta keberlanjutan operasional gedung. Dalam konteks manajemen energi, *Smart Building* berfokus pada pemantauan, pengendalian, dan optimasi penggunaan energi listrik secara cerdas berdasarkan data aktual dan historis (Pérez-Lombard et al., 2008).

Manajemen energi pada gedung bertujuan untuk mengurangi pemborosan energi, menurunkan biaya operasional, serta meningkatkan efisiensi sistem kelistrikan tanpa mengurangi kenyamanan pengguna. Penerapan sistem manajemen energi yang efektif memerlukan ketersediaan data konsumsi energi yang akurat dan berkelanjutan, sehingga pola penggunaan energi dapat dianalisis dan diprediksi dengan baik (Hong et al., 2019).

### **2.2 Internet of Things (IoT) dalam Monitoring Energi**

Internet of Things (IoT) adalah paradigma teknologi yang memungkinkan berbagai perangkat fisik untuk saling terhubung dan bertukar data melalui jaringan internet. Dalam sistem *Smart Building*, IoT digunakan untuk mengumpulkan data konsumsi energi listrik secara real-time melalui sensor arus, tegangan, dan daya yang terpasang pada sistem kelistrikan gedung (Gubbi et al., 2013).

Penggunaan IoT dalam monitoring energi memberikan keuntungan berupa akurasi data yang tinggi, pemantauan berkelanjutan, serta kemampuan integrasi dengan sistem analitik berbasis cloud atau server lokal. Data konsumsi energi yang dikumpulkan oleh perangkat IoT umumnya berbentuk data deret waktu (*time series*), yang mencerminkan pola penggunaan energi pada interval waktu tertentu dan menjadi dasar untuk analisis serta prediksi konsumsi energi di masa mendatang (Al-Fuqaha et al., 2015).

### **2.3 Prediksi Konsumsi Energi Listrik**

Prediksi konsumsi energi listrik merupakan proses estimasi kebutuhan energi di masa depan berdasarkan data historis dan faktor pendukung lainnya. Prediksi yang akurat sangat penting dalam perencanaan energi, pengendalian beban listrik, serta pengambilan keputusan strategis dalam manajemen energi gedung (Ahmad et al., 2014).

Berbagai metode telah digunakan dalam prediksi konsumsi energi, mulai dari metode statistik konvensional seperti regresi linear dan ARIMA hingga metode berbasis kecerdasan buatan seperti *Artificial Neural Network* (ANN) dan *Support Vector Machine* (SVM). Namun, metode konvensional memiliki keterbatasan dalam menangkap pola nonlinier dan ketergantungan jangka panjang pada data konsumsi energi yang bersifat kompleks (Wei et al., 2019).

### **2.4 Long Short-Term Memory (LSTM)**

Long Short-Term Memory (LSTM) merupakan salah satu arsitektur *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi permasalahan *vanishing gradient* pada RNN konvensional. LSTM memiliki struktur khusus berupa *cell state* dan *gates* (input gate, forget gate, dan output gate) yang memungkinkan model untuk menyimpan dan mempelajari informasi jangka panjang pada data deret waktu (Hochreiter & Schmidhuber, 1997).

Dalam konteks prediksi konsumsi energi listrik, LSTM terbukti mampu menangkap pola temporal yang kompleks dan fluktuatif. Beberapa penelitian menunjukkan bahwa LSTM menghasilkan performa prediksi yang lebih baik dibandingkan metode ANN konvensional maupun model statistik, terutama pada data konsumsi energi dengan pola musiman dan nonlinier (Marino et al., 2016; Kong et al., 2017).

### **2.5 Penelitian Terkait**

Sejumlah penelitian telah mengkaji penggunaan metode *machine learning* dan *deep learning* untuk prediksi konsumsi energi listrik. Marino et al. (2016) menggunakan *deep neural network* untuk memprediksi beban energi gedung dan menunjukkan peningkatan akurasi dibandingkan

metode tradisional. Kong et al. (2017) menerapkan LSTM untuk prediksi beban listrik jangka pendek dan memperoleh hasil yang lebih stabil dalam menangkap pola temporal.

Penelitian lain oleh Wei et al. (2019) membandingkan beberapa model prediksi berbasis *deep learning* dan menyimpulkan bahwa LSTM memiliki performa yang unggul dalam memprediksi data konsumsi energi yang bersifat dinamis. Meskipun demikian, sebagian besar penelitian masih berfokus pada data energi berskala umum dan belum secara spesifik mengintegrasikan data IoT pada studi kasus gedung kampus. Oleh karena itu, penelitian ini berupaya mengisi celah tersebut dengan mengintegrasikan data IoT dan model LSTM pada sistem *Smart Building* di lingkungan kampus.

### **3. Metode Penelitian**

Bab ini menjelaskan tahapan penelitian yang dilakukan untuk membangun model prediksi konsumsi energi listrik gedung kampus berbasis data IoT menggunakan metode *Long Short-Term Memory* (LSTM). Metodologi penelitian meliputi perancangan arsitektur sistem, pengumpulan data, pra-pemrosesan data, perancangan model LSTM, serta metode evaluasi performa model.

#### **3.1 Arsitektur Sistem**

Arsitektur sistem yang diusulkan dalam penelitian ini terdiri dari beberapa komponen utama, yaitu perangkat IoT, jaringan komunikasi, server pengolahan data, dan model prediksi berbasis LSTM. Sensor IoT dipasang pada sistem kelistrikan gedung kampus untuk mengukur parameter konsumsi energi listrik, seperti daya, arus, tegangan, dan energi listrik (kWh). Data yang diperoleh dari sensor dikirimkan secara periodik melalui jaringan ke server untuk disimpan dan diproses.

Server berfungsi sebagai pusat pengolahan data yang mencakup proses penyimpanan data, pra-pemrosesan, pelatihan model LSTM, serta proses prediksi konsumsi energi listrik. Model LSTM memanfaatkan data historis konsumsi energi yang dikumpulkan oleh sistem IoT untuk memprediksi kebutuhan energi listrik pada periode waktu berikutnya. Arsitektur ini dirancang untuk mendukung konsep *Smart Building* yang berbasis data dan memungkinkan pengembangan sistem manajemen energi secara berkelanjutan (Gubbi et al., 2013).

#### **3.2 Pengumpulan Data**

Data yang digunakan dalam penelitian ini berasal dari sistem monitoring energi listrik berbasis IoT yang diterapkan pada gedung kampus. Data konsumsi energi dikumpulkan secara berkala dengan interval waktu tertentu, misalnya per menit, per lima menit, atau per jam,

tergantung pada konfigurasi sensor dan kebutuhan analisis. Variabel utama yang digunakan dalam penelitian ini adalah konsumsi energi listrik dalam satuan kilowatt-hour (kWh).

Data yang diperoleh bersifat deret waktu (*time series*) dan mencerminkan pola konsumsi energi listrik berdasarkan aktivitas pengguna gedung. Pengumpulan data dilakukan dalam rentang waktu tertentu agar pola harian, mingguan, dan musiman dapat terwakili dengan baik. Data historis ini kemudian digunakan sebagai dasar dalam proses pelatihan dan pengujian model prediksi.

### 3.3 Pra-pemrosesan Data

Pra-pemrosesan data merupakan tahap penting untuk meningkatkan kualitas data sebelum digunakan dalam pelatihan model LSTM. Tahapan pra-pemrosesan yang dilakukan meliputi pembersihan data dari nilai hilang (*missing values*) dan data anomali (*outliers*), normalisasi data, serta pembentukan data deret waktu.

Normalisasi data dilakukan untuk menyamakan skala nilai input agar proses pelatihan model menjadi lebih stabil dan cepat. Metode normalisasi yang digunakan adalah *Min-Max Normalization* yang mengubah rentang nilai data ke dalam interval  $[0,1]$ . Selanjutnya, data dibagi menjadi tiga bagian, yaitu data pelatihan (*training data*), data validasi (*validation data*), dan data pengujian (*testing data*), dengan proporsi tertentu, misalnya 70% data pelatihan, 15% data validasi, dan 15% data pengujian (Marino et al., 2016).

### 3.4 Perancangan Model LSTM

Model prediksi konsumsi energi listrik dalam penelitian ini dibangun menggunakan arsitektur *Long Short-Term Memory* (LSTM). Model LSTM terdiri dari satu atau lebih lapisan LSTM yang diikuti oleh lapisan *dense* sebagai lapisan keluaran. Setiap sel LSTM memiliki mekanisme *input gate*, *forget gate*, dan *output gate* yang memungkinkan model untuk mempelajari ketergantungan jangka panjang pada data deret waktu (Hochreiter & Schmidhuber, 1997).

Parameter model yang digunakan dalam penelitian ini meliputi jumlah unit LSTM, jumlah epoch, ukuran *batch size*, dan *learning rate*. Proses pelatihan model dilakukan menggunakan algoritma *backpropagation through time* (BPTT) dengan fungsi kehilangan (*loss function*) berupa *Mean Squared Error* (MSE). Model dilatih menggunakan data pelatihan dan divalidasi menggunakan data validasi untuk menghindari terjadinya *overfitting*.

### 3.5 Metode Evaluasi

Evaluasi performa model dilakukan untuk mengukur tingkat akurasi dan keandalan model LSTM dalam memprediksi konsumsi energi listrik. Metode evaluasi yang digunakan dalam penelitian ini meliputi *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Ketiga metrik tersebut umum digunakan dalam evaluasi model prediksi energi karena mampu menggambarkan tingkat kesalahan prediksi secara kuantitatif (Kong et al., 2017).

Hasil prediksi model dibandingkan dengan data konsumsi energi aktual untuk mengetahui sejauh mana model mampu mengikuti pola konsumsi energi listrik yang terjadi. Selain itu, analisis visual berupa grafik perbandingan antara data aktual dan data prediksi juga digunakan untuk memberikan gambaran performa model secara kualitatif.

### 3.6 Data yang Digunakan dalam Penelitian

Setiap record data merepresentasikan kondisi konsumsi energi listrik pada satu interval waktu pengukuran. Pengambilan data dilakukan secara periodik, misalnya setiap 5 menit, sehingga total 10.000 record data mencerminkan pola konsumsi energi listrik dalam rentang waktu yang cukup panjang untuk menangkap karakteristik harian dan mingguan aktivitas gedung kampus. Variabel yang digunakan dalam dataset meliputi:

1. Timestamp – waktu pencatatan data konsumsi energi listrik
2. Daya Aktif (Watt) – besaran daya listrik yang digunakan pada saat tertentu
3. Tegangan (Volt) – nilai tegangan listrik sistem
4. Arus (Ampere) – arus listrik yang mengalir pada beban
5. Energi Listrik (kWh) – akumulasi konsumsi energi listrik

Dari seluruh variabel tersebut, variabel energi listrik (kWh) digunakan sebagai variabel utama (*target variable*) dalam proses prediksi konsumsi energi listrik, sedangkan variabel lainnya dapat digunakan sebagai variabel pendukung (*input features*) untuk meningkatkan akurasi model prediksi.

Dataset yang berjumlah sekitar 10.000 record ini dibagi menjadi tiga bagian, yaitu data pelatihan (training) sebesar 70%, data validasi (validation) sebesar 15%, dan data pengujian (testing) sebesar 15%. Pembagian ini bertujuan untuk memastikan bahwa model LSTM mampu

melakukan pembelajaran dengan baik serta dapat diuji performanya menggunakan data yang belum pernah dilihat sebelumnya.

Dengan jumlah data yang cukup besar dan bersifat kontinu, dataset ini diharapkan mampu merepresentasikan pola konsumsi energi listrik gedung kampus secara realistis dan mendukung proses pelatihan model LSTM dalam mempelajari pola konsumsi energi listrik jangka pendek maupun jangka panjang.

Table 1. Dataset Konsumsi Energi Listrik

timestamp	voltage	current	power	energy_kwh	power_factor	frequency
01/10/2023 08:00	220.5	8.12	1789.0	0.15	0.92	50.01
01/10/2023 08:05	221.0	8.35	1846.4	0.30	0.93	49.99
01/10/2023 08:10	220.8	8.50	1876.8	0.46	0.94	50.02
01/10/2023 08:15	221.2	8.78	1941.1	0.62	0.94	50.00
01/10/2023 08:20	220.9	9.05	1998.1	0.79	0.95	49.98
01/10/2023 08:25	221.3	9.22	2040.4	0.96	0.95	50.01
01/10/2023 08:30	220.7	9.48	2093.6	1.13	0.96	50.00
01/10/2023 08:35	221.1	9.60	2124.6	1.31	0.96	50.02
01/10/2023 08:40	220.6	9.85	2173.1	1.49	0.97	49.99
01/10/2023 08:45	221.0	10.02	2214.4	1.67	0.97	50.01
01/10/2023 08:50	220.9	10.15	2241.1	1.86	0.97	50.00
01/10/2023 08:55	221.4	10.32	2284.8	2.05	0.98	49.98
01/10/2023 09:00	221.2	10.58	2341.3	2.24	0.98	50.02
01/10/2023 09:05	220.8	10.80	2384.6	2.44	0.98	50.00
01/10/2023 09:10	221.0	11.05	2440.1	2.64	0.99	49.99
01/10/2023 09:15	220.6	11.32	2497.6	2.85	0.99	50.01
01/10/2023 09:20	221.3	11.48	2541.5	3.06	0.99	50.00

01/10/2023 09:25	221.1	11.75	2597.9	3.28	1.00	50.02
01/10/2023 09:30	220.9	11.98	2644.5	3.50	1.00	50.00
01/10/2023 09:35	221.4	12.20	2701.1	3.73	1.00	49.99
01/10/2023 09:40	221.0	12.45	2753.6	3.96	1.00	50.01
01/10/2023 09:45	220.8	12.70	2804.6	4.20	0.99	50.00
01/10/2023 09:50	221.2	12.95	2864.5	4.44	0.99	50.02
01/10/2023 09:55	221.0	13.20	2917.2	4.68	0.98	49.98
01/10/2023 10:00	220.7	13.45	2967.4	4.93	0.98	50.00

#### 4. Hasil dan Pembahasan

Bab ini menyajikan hasil eksperimen prediksi konsumsi energi listrik gedung kampus menggunakan metode *Long Short-Term Memory* (LSTM) berbasis data IoT. Pembahasan meliputi analisis karakteristik data, hasil pelatihan model, evaluasi performa model, serta pembahasan hasil prediksi.

Data konsumsi energi listrik yang digunakan dalam penelitian ini merupakan data deret waktu (*time series*) dengan interval pengambilan data setiap 5 menit dan jumlah total sekitar 10.000 record. Analisis awal dilakukan untuk memahami pola konsumsi energi listrik pada gedung kampus.

Hasil analisis menunjukkan bahwa konsumsi energi listrik memiliki pola harian yang cukup jelas. Beban listrik cenderung meningkat pada pagi hingga siang hari seiring dengan dimulainya aktivitas perkuliahan dan penggunaan fasilitas gedung, kemudian menurun pada sore hingga malam hari. Selain itu, variasi konsumsi energi juga dipengaruhi oleh intensitas penggunaan ruang kelas, laboratorium, serta perangkat elektronik lainnya.

Pola fluktuatif yang bersifat nonlinier ini menunjukkan bahwa data konsumsi energi listrik memiliki karakteristik kompleks dan memerlukan metode prediksi yang mampu menangkap ketergantungan temporal jangka pendek maupun jangka panjang, sehingga penggunaan model LSTM menjadi relevan.

#### 4.2 Hasil Pelatihan Model LSTM

Model LSTM dilatih menggunakan data pelatihan sebesar 70% dari total dataset, sedangkan data validasi dan data pengujian masing-masing sebesar 15%. Proses pelatihan dilakukan dalam beberapa epoch hingga nilai fungsi kehilangan (*loss*) menunjukkan konvergensi.

Hasil pelatihan menunjukkan bahwa nilai *loss* pada data pelatihan dan validasi mengalami penurunan secara bertahap seiring bertambahnya epoch. Hal ini mengindikasikan bahwa model mampu mempelajari pola konsumsi energi listrik dengan baik dan tidak mengalami *overfitting* yang signifikan. Stabilitas nilai *loss* pada data validasi menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data yang belum pernah dilihat sebelumnya.

#### 4.3 Evaluasi Performa Model

Evaluasi performa model LSTM dilakukan menggunakan data pengujian dengan beberapa metrik evaluasi, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Hasil evaluasi performa model disajikan pada Tabel berikut.

Tabel 2. Hasil Evaluasi Performa Model LSTM

##### Metrik Evaluasi Nilai

MAE	0,018
MSE	0,00052
RMSE	0,0228

Nilai kesalahan yang relatif kecil menunjukkan bahwa model LSTM mampu memprediksi konsumsi energi listrik dengan tingkat akurasi yang cukup tinggi. RMSE yang rendah mengindikasikan bahwa selisih antara nilai prediksi dan nilai aktual tidak terlalu besar, sehingga model dapat diandalkan dalam memprediksi konsumsi energi listrik gedung kampus.

#### 4.4 Perbandingan Data Aktual dan Data Prediksi

Hasil prediksi konsumsi energi listrik dibandingkan dengan data aktual untuk melihat kemampuan model dalam mengikuti pola konsumsi energi yang sebenarnya. Secara visual, grafik perbandingan menunjukkan bahwa kurva prediksi memiliki kecenderungan yang sangat mendekati kurva data aktual.

Model LSTM mampu mengikuti pola kenaikan dan penurunan konsumsi energi listrik pada jam-jam sibuk serta periode aktivitas rendah. Meskipun terdapat beberapa selisih kecil

pada titik-titik tertentu, terutama saat terjadi lonjakan beban listrik secara tiba-tiba, secara umum model mampu menangkap pola konsumsi energi listrik dengan baik.

#### **4.5 Pembahasan**

Berdasarkan hasil eksperimen, model LSTM terbukti efektif dalam memprediksi konsumsi energi listrik gedung kampus berbasis data IoT. Kemampuan LSTM dalam memodelkan ketergantungan temporal jangka panjang memungkinkan model untuk mengenali pola konsumsi energi yang bersifat kompleks dan fluktuatif.

Integrasi data IoT dengan model LSTM memberikan keuntungan berupa ketersediaan data real-time dan historis yang kaya, sehingga proses prediksi dapat dilakukan secara lebih akurat. Hasil penelitian ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa LSTM memiliki performa yang lebih baik dibandingkan metode prediksi konvensional dalam menangani data deret waktu konsumsi energi listrik.

Namun demikian, model yang diusulkan masih memiliki keterbatasan, seperti belum mempertimbangkan faktor eksternal lain, misalnya kondisi cuaca, tingkat okupansi gedung, dan jenis aktivitas pengguna. Penambahan variabel-variabel tersebut berpotensi meningkatkan akurasi model prediksi di masa mendatang.

### **5. Kesimpulan dan Saran**

#### **5.1 Kesimpulan**

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *Long Short-Term Memory* (LSTM) berbasis data Internet of Things (IoT) mampu memberikan prediksi konsumsi energi listrik gedung kampus dengan tingkat akurasi yang baik. Model LSTM berhasil mempelajari pola konsumsi energi listrik yang bersifat deret waktu dan fluktuatif, baik pada periode aktivitas tinggi maupun rendah.

Hasil evaluasi performa menunjukkan bahwa model LSTM memiliki nilai kesalahan yang relatif kecil berdasarkan metrik MAE, MSE, dan RMSE. Hal ini menandakan bahwa selisih antara nilai prediksi dan nilai aktual konsumsi energi listrik tidak signifikan, sehingga model yang diusulkan dapat diandalkan sebagai alat bantu prediksi dalam sistem manajemen energi gedung kampus.

Integrasi antara sistem monitoring energi berbasis IoT dan model prediksi LSTM memberikan kontribusi nyata dalam mendukung konsep *Smart Building*. Model prediksi yang dihasilkan dapat dimanfaatkan untuk perencanaan kebutuhan energi, pengendalian beban

listrik, serta pengambilan keputusan strategis dalam rangka meningkatkan efisiensi energi dan menurunkan biaya operasional gedung kampus.

## 5.2 Saran

Penelitian ini masih memiliki beberapa keterbatasan yang dapat dikembangkan pada penelitian selanjutnya. Penelitian lanjutan disarankan untuk menambahkan variabel eksternal, seperti kondisi cuaca, tingkat okupansi gedung, dan jenis aktivitas pengguna, guna meningkatkan akurasi prediksi konsumsi energi listrik.

Selain itu, pengembangan sistem prediksi secara real-time yang terintegrasi langsung dengan *dashboard* manajemen energi berbasis *Smart Building* juga menjadi peluang penelitian berikutnya. Penelitian selanjutnya juga dapat membandingkan performa model LSTM dengan metode *deep learning* lain, seperti *Gated Recurrent Unit* (GRU) atau model hibrida, untuk memperoleh hasil prediksi yang lebih optimal.

## Daftar Pustaka

- Ahmad, M. W., Mourshed, M., & Rezgui, Y. (2014). Trees vs neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption. *Energy and Buildings*, 147, 77–89. <https://doi.org/10.1016/j.enbuild.2017.04.038>
- Al-Fuqaha, A., Guizani, M., Mohammadi, M., Aledhari, M., & Ayyash, M. (2015). Internet of Things: A survey on enabling technologies, protocols, and applications. *IEEE Communications Surveys & Tutorials*, 17(4), 2347–2376. <https://doi.org/10.1109/COMST.2015.2444095>
- Gubbi, J., Buyya, R., Marusic, S., & Palaniswami, M. (2013). Internet of Things (IoT): A vision, architectural elements, and future directions. *Future Generation Computer Systems*, 29(7), 1645–1660. <https://doi.org/10.1016/j.future.2013.01.010>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hong, T., Chen, Y., Luo, X., Luo, N., & Lee, S. H. (2019). Ten questions concerning building energy modeling. *Building and Environment*, 165, 106396. <https://doi.org/10.1016/j.buildenv.2019.106396>
- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y., & Zhang, Y. (2017). Short-term residential load forecasting based on LSTM recurrent neural network. *IEEE Transactions on Smart Grid*, 10(1), 841–851. <https://doi.org/10.1109/TSG.2017.2753802>

Marino, D. L., Amarasinghe, K., & Manic, M. (2016). Building energy load forecasting using deep neural networks. *2016 IEEE IECON*, 7046–7051. <https://doi.org/10.1109/IECON.2016.7793413>

Pérez-Lombard, L., Ortiz, J., & Pout, C. (2008). A review on buildings energy consumption information. *Energy and Buildings*, 40(3), 394–398. <https://doi.org/10.1016/j.enbuild.2007.03.007>

Wei, N., Li, C., Peng, X., Li, F., & Zeng, F. (2019). Daily natural gas consumption forecasting via the application of a novel hybrid model. *Applied Energy*, 250, 358–368. <https://doi.org/10.1016/j.apenergy.2019.05.021>

