



Metode Long Short-Term Memory Untuk Memprediksi Konsumsi Energi Listrik Di Kabupaten Kebumen Tahun 2023

Jatmiar Fikriaziz¹, Mutia Nur Estri², Sri Maryani³, Idha Sihwaningrum⁴

^{1,2,3,4}Jurusan Matematika, Universitas Jenderal Soedirman

¹jatmiar.fikriaziz@mhs.unsoed.ac.id, ²mutia.estri@unsoed.ac.id, ³sri.maryani@unsoed.ac.id,

⁴idha.sihwaningrum@unsoed.ac.id

Corresponding author email: mutia.estri@unsoed.ac.id

Abstract: *Electrical energy is a basic source for humans to carry out various activities. Currently, Indonesia's electrical energy supply is on standby status because few remaining reserves are available. Therefore, it is necessary to have an electricity prediction to determine the amount of energy consumption in Indonesia in the future, especially in Kebumen Regency. Prediction results that are close to reality results require the application of optimal methods. One method that can be used to predict electrical energy consumption is Long Short-Term Memory (LSTM). This paper aims to describe the mechanism of the LSTM method, estimate the amount of electrical energy consumption in Kebumen Regency in 2023, and determine the accuracy of the LSTM method in predicting electrical energy consumption in Kebumen Regency. The data used in this research is data on electrical energy consumption in Kebumen Regency from January 2018 to March 2023. This data is time series data with monthly intervals. The LSTM method has high accuracy in predicting electrical energy consumption in Kebumen Regency with a MAPE value of 4.07%*

Keywords: *electrical energy, Long Short-Term Memory, prediction, , time series*

Abstrak: Energi listrik merupakan salah satu sumber energi dasar yang sangat dibutuhkan oleh manusia dalam menjalankan berbagai aktivitas. Saat ini, pasokan energi listrik Indonesia berada pada status siaga karena cadangan yang tersisa tidak banyak tersedia. Oleh karena itu, diperlukan adanya suatu prediksi untuk mengetahui jumlah konsumsi energi listrik di Indonesia pada masa mendatang khususnya di Kabupaten Kebumen. Hasil prediksi yang mendekati hasil realitasnya memerlukan penerapan metode yang optimal. Salah satu metode yang dapat digunakan untuk memprediksi konsumsi energi listrik adalah *Long Short-Term Memory (LSTM)*. Paper ini bertujuan untuk menjabarkan mekanisme metode LSTM, memperkirakan jumlah konsumsi energi listrik di Kabupaten Kebumen pada tahun 2023, dan menentukan akurasi metode LSTM dalam memprediksi konsumsi energi listrik di Kabupaten Kebumen. Data yang digunakan dalam penelitian ini adalah data konsumsi energi listrik di Kabupaten Kebumen pada bulan Januari 2018 sampai Maret 2023. Data tersebut merupakan data *time series* yang memiliki interval per bulan. Metode LSTM memiliki akurasi yang tinggi dalam memprediksi konsumsi energi listrik di Kabupaten Kebumen dengan nilai MAPE sebesar 4,07%.

Kata kunci: energi Listrik, *Long Short-Term Memory*, prediksi, *time series*

I. PENDAHULUAN

Energi listrik merupakan salah satu sumber energi dasar yang sangat dibutuhkan oleh manusia dalam menjalankan berbagai aktivitas untuk meningkatkan produktivitas kerja. Seiring dengan meningkatnya pertumbuhan jumlah penduduk dan tingkat ekonomi, serta kemajuan teknologi, maka kebutuhan energi listrik akan terus meningkat setiap tahun [1]. Pasokan listrik Indonesia berada pada status siaga karena cadangan yang tersisa tidak banyak tersedia[6]. Dengan demikian, diperlukan adanya suatu prediksi untuk mengetahui jumlah konsumsi energi listrik di Indonesia pada masa mendatang.

Prediksi konsumsi energi listrik juga memiliki peran penting dalam rencana untuk meningkatkan kinerja energi, menghemat energi, dan mengurangi dampak lingkungan yang berbahaya. Selain itu, prediksi tersebut juga menjadi penting dalam pengambilan keputusan dan perencanaan masa depan yang bergantung pada perkiraan yang akurat [1]. Hasil prediksi yang terlalu rendah (*under estimate*) dapat mengakibatkan terjadinya pemadaman listrik bergilir dan pasokan energi listrik tidak mencukupi untuk kebutuhan kehidupan masyarakat. Sebaliknya, hasil perkiraan yang terlalu tinggi (*over estimate*) akan mengakibatkan investasi yang terlalu besar dan dapat merugikan perusahaan [8]. Oleh karena itu diperlukan penerapan metode yang optimal agar hasil yang diperoleh mendekati hasil realitasnya.



Berdasarkan permasalahan tersebut, diperlukan sistem yang mampu menghasilkan akurasi yang tepat dalam memprediksi konsumsi energi listrik di Indonesia pada masa yang akan datang [6]. Penelitian tentang perkiraan kebutuhan energi listrik telah dilakukan Rahman (2015) [11] di provinsi Sumatra Barat dengan metode regresi linier berganda. Syafruddin (2015) [13] juga telah melakukan prediksi kebutuhan energi listrik jangka panjang untuk provinsi Bali menggunakan metode regresi linier.

Metode regresi linier dapat memperoleh hasil yang memuaskan ketika memecahkan masalah-masalah linier, tetapi kurang efektif dalam memprediksi masalah nonlinier atau data yang bersifat acak. Sementara itu, metode yang didasarkan pada *machine learning* merupakan pendekatan yang menggunakan algoritma untuk mengajarkan komputer dalam menyelesaikan suatu permasalahan berdasarkan data yang diberikan. Komputer akan menggunakan data tersebut untuk menemukan pola atau hubungan yang ada secara otomatis tanpa aturan yang ditentukan sebelumnya oleh manusia. Metode ini dapat digunakan untuk memecahkan masalah-masalah linier dan nonlinier. Metode *Artificial Neural Networks* (ANN) dan *Support Vector Machine* (SVM) termasuk dalam pendekatan *machine learning* yang biasa digunakan dalam prediksi data konsumsi energi listrik [5]. Meskipun demikian, metode ANN dan SVM memiliki keterbatasan dalam menangani masalah data berurutan, seperti data *time series* [9].

Metode *Long Short-Term Memory* (LSTM) dapat digunakan untuk mengatasi kelemahan dalam menangani masalah data berurutan, seperti data *time series*. Metode LSTM merupakan arsitektur baru dari RNN yang didasarkan pada blok memori. Blok memori dan tiga unit gerbang (*gate units*), yaitu *forget gate*, *input gate*, dan *output gate*, yang membantu dalam pengelolaan gradien dan informasi dalam rangkaian panjang (*long sequences*). Karakteristik unik dari unit-unit gerbang yang ada di unit tersembunyi (*hidden units*) dapat membantu dalam menjaga data yang relevan dan melupakan data yang tidak relevan selama pemrosesan data. Hal ini bertujuan untuk memberikan kesalahan yang konsisten (*constant error*) selama proses pembelajaran [12]. Penelitian yang berkaitan dengan metode LSTM pernah dilakukan Zheng, dkk. (2017) [15] untuk memprediksi beban listrik pada *smart grid*. Pada penelitian tersebut diperoleh akurasi yang tinggi dengan nilai MAPE sebesar 5%. Peneliti lain melakukan peramalan banjir menggunakan metode LSTM [9]. Penelitian yang dilakukan tersebut memperoleh hasil evaluasi yang baik dengan nilai *Nash-Sutcliffe Efficiency* (NSE) sebesar 87%. Secara umum, metode LSTM dapat digunakan pada data *time series* yang linier dan nonlinier. Oleh karena itu, penulis tertarik melakukan penelitian untuk memprediksi konsumsi energi listrik di Kabupaten Kebumen menggunakan metode LSTM.

II. METODE PENELITIAN

Metode penelitian yang digunakan dalam makalah ini adalah studi pustaka dan studi kasus. Penulis mengumpulkan, mempelajari, dan menelaah literatur berupa buku, jurnal, atau penelitian sebelumnya yang membahas tentang metode LSTM. Selanjutnya mengaplikasikan metode LSTM untuk memprediksi jumlah energi listrik yang dikonsumsi pada tahun 2023 di Kabupaten Kebumen. Proses pembuatan model dan hasil prediksi dilakukan menggunakan *google colab* dengan bahasa pemrograman Python.

2.1. Deskripsi Data

Data yang digunakan pada penelitian ini merupakan data sekunder, yaitu data yang dikumpulkan dari data yang sudah ada sebelumnya. Data diperoleh dari PLN Unit Layanan Pelanggan Kebumen (Tabel 1). Data tersebut merupakan data konsumsi energi listrik per bulan di Kabupaten Kebumen pada



bulan Januari 2018 sampai Maret 2023. Data disusun menjadi *time series* dengan rentang waktu bulanan dan terdiri 3 kolom. Dengan demikian, data yang digunakan berukuran 63 baris dan 3 kolom.

Tabel 1. Data konsumsi energi listrik di Kabupaten Kebumen

	Konsumsi energi listrik (kWh)					
	2018	2019	2020	2021	2022	2023
Januari	23.543.455	25.584.991	28.711.421	20.621.293	21.948.782	33.518.691
Februari	21.698.806	23.803.152	26.503.323	28.359.105	28.257.153	30.260.397
Maret	24.374.770	26.239.587	28.069.624	31.354.899	31.021.435	34.238.166
April	24.071.263	19.216.774	20.160.474	21.110.822	31.990.770	
Mei	25.530.256	28.291.635	31.320.486	22.201.490	34.375.823	
Juni	25.671.669	26.746.544	30.157.299	21.249.133	21.613.728	
Juli	24.047.081	25.704.994	30.456.544	20.792.239	32.321.325	
Agustus	17.458.696	25.327.200	29.787.339	30.197.491	32.353.280	
September	17.355.814	18.044.751	29.942.681	20.664.115	21.735.115	
Oktober	25.483.752	19.307.183	30.499.651	30.861.898	32.227.659	
November	24.998.331	19.494.198	30.584.938	21.130.945	31.628.831	
Desember	25.633.580	28.655.206	26.066.869	21.613.891	33.068.660	

2.2. Normalisasi Data

Menurut Brownlee [3], normalisasi data adalah teknik perubahan skala pada data yang dilakukan dengan cara mengubah rentang nilai data asli sehingga semua nilai berada pada interval $[1, 0]$. Proses normalisasi ini hanya mengubah nilainya saja tanpa menghilangkan informasi di dalamnya. Normalisasi data dapat digunakan untuk menghindari atau meminimalkan anomali pada data. Normalisasi data dapat dilakukan menggunakan rumus berikut:

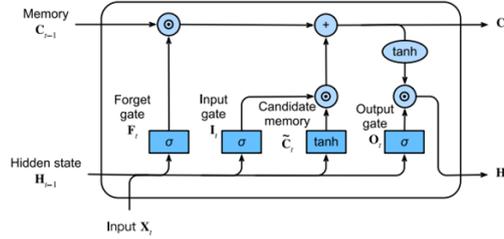
$$z = \frac{w - \min(w)}{\max(w) - \min(w)}, \quad (1)$$

2.3. Pembagian Data Latih dan Data Uji

Pembagian data latih dan data uji merupakan suatu cara yang dapat digunakan untuk mengevaluasi kinerja sebuah algoritma. Masing-masing data latih dan data uji dibagi menjadi *input* dan *output*. Data latih digunakan untuk mempersiapkan model dalam melakukan *training*. Data uji merupakan data baru yang nilai *output*-nya disembunyikan dari algoritma [3]. Pada data yang jumlahnya relatif kecil, proporsi data latih dan data uji yang biasa digunakan adalah 80% dan 20%. Pada data yang relatif besar, proporsi data latih dan data uji yang biasa digunakan adalah 70% dan 30%.

2.4. Long short-term memory

Long short-term memory (LSTM) merupakan perkembangan dari *Recurrent Neural Network* (RNN) untuk mengatasi masalah *vanishing* dan *exploding gradient* pada RNN. Secara umum, LSTM terdiri dari *memory cell*, *candidate memory cell*, dan *gate* LSTM. *Gate* LSTM terdiri dari *forget gate*, *input gate*, dan *output gate*. *Forget gate* berfungsi untuk menentukan *input* sel LSTM pada *time step* saat ini akan disimpan atau dihilangkan. *Input gate* berfungsi untuk menentukan seberapa banyak nilai *input* yang harus ditambahkan ke dalam *memory cell*. *Output gate* berfungsi untuk menentukan nilai dari sel yang akan digunakan untuk menghitung *output*. Arsitektur LSTM dapat dilihat pada Gambar 1[14].



Gambar 1. Arsitektur LSTM

Hidden state dari sel sebelumnya dan *input* saat ini yang masuk pada *forget gate* akan diolah dan dipilih informasi yang akan disimpan pada *memory cell*. Proses pengolahannya menggunakan Fungsi aktivasi sigmoid. Proses pada *forget gate* dapat diilustrasikan pada persamaan (2). Kemudian *hidden state* dari sel sebelumnya dan *input* saat ini akan masuk pada *input gate* dan *candidate memory cell* untuk memperbaharui informasi dan menyimpannya pada *memory cell*. Fungsi aktivasinya menggunakan sigmoid dan tanh. Proses ini dapat digambarkan pada persamaan (3) dan (4)[14].

$$\mathbf{F}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xf} + \mathbf{H}_{t-1} \mathbf{W}_{hf} + \mathbf{B}_f) \quad (2)$$

dengan

- $\mathbf{F}_t \in \mathbb{R}^{n \times p}$: matriks *forget gate* pada *time step* t ;
- σ : fungsi aktivasi sigmoid
- $\mathbf{X}_t \in \mathbb{R}^{n \times d}$: matriks *input* pada *time step* t ;
- $\mathbf{W}_{xf} \in \mathbb{R}^{d \times p}$: matriks bobot yang menghubungkan *input node* (x) dengan *forget gate* (f) pada *time step* t ;
- $\mathbf{H}_{t-1} \in \mathbb{R}^{n \times p}$: matriks *hidden state* pada *time step* $t - 1$;
- $\mathbf{W}_{hf} \in \mathbb{R}^{p \times p}$: matriks bobot yang menghubungkan *hidden node* (h) pada *time step* $t - 1$ dengan *forget gate* (f) pada *time step* t ;
- $\mathbf{B}_f \in \mathbb{R}^{n \times p}$: matriks parameter bias pada *forget gate* *time step* t dan $\mathbf{B}_f = [b_{ij}]$ dengan $b_{ij} = b_{kj}$ untuk setiap $i, k = 1, 2, \dots, n$ dan $j = 1, 2, \dots, p$.

$$\mathbf{I}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xu} + \mathbf{H}_{t-1} \mathbf{W}_{hu} + \mathbf{B}_u) \quad (3)$$

dengan

- $\mathbf{I}_t \in \mathbb{R}^{n \times p}$: matriks *input gate* pada *time step* t ;
- σ : fungsi aktivasi sigmoid
- $\mathbf{X}_t \in \mathbb{R}^{n \times d}$: matriks *input* pada *time step* t ;
- $\mathbf{W}_{xu} \in \mathbb{R}^{d \times p}$: matriks bobot yang menghubungkan *input node* (x) dengan *input gate* (u) pada *time step* t ;
- $\mathbf{H}_{t-1} \in \mathbb{R}^{n \times p}$: matriks *hidden state* pada *time step* $t - 1$;
- $\mathbf{W}_{hu} \in \mathbb{R}^{p \times p}$: matriks bobot yang menghubungkan *hidden node* (h) pada *time step* $t - 1$ dengan *input gate* (u) pada *time step* t ;
- $\mathbf{B}_u \in \mathbb{R}^{n \times p}$: matriks parameter bias pada *input gate* *time step* t dan $\mathbf{B}_u = [b_{ij}]$ dengan $b_{ij} = b_{kj}$ untuk setiap $i, k = 1, 2, \dots, n$ dan $j = 1, 2, \dots, p$.

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{X}_t \mathbf{W}_{xc} + \mathbf{H}_{t-1} \mathbf{W}_{hc} + \mathbf{B}_c) \quad (4)$$

dengan



- $\tilde{\mathbf{C}}_t \in \mathbb{R}^{n \times p}$: matriks *candidate memory cell* pada *time step* t ;
 \tanh : fungsi aktivasi tanh;
 $\mathbf{X}_t \in \mathbb{R}^{n \times d}$: matriks *input* pada *time step* t ;
 $\mathbf{W}_{xc} \in \mathbb{R}^{d \times p}$: matriks bobot yang menghubungkan *input node* (x) dengan *candidate memory cell* (c) pada *time step* t ;
 $\mathbf{H}_{t-1} \in \mathbb{R}^{n \times p}$: matriks *hidden state* pada *time step* $t - 1$;
 $\mathbf{W}_{hc} \in \mathbb{R}^{p \times p}$: matriks bobot yang menghubungkan *hidden node* (h) pada *time step* $t - 1$ dengan *candidate memory cell* (c) pada *time step* t ;
 $\mathbf{B}_c \in \mathbb{R}^{n \times p}$: matriks parameter bias pada *candidate memory cell* *time step* t dan $\mathbf{B}_c = [b_{ij}]$ dengan $b_{ij} = b_{kj}$ untuk setiap $i, k = 1, 2, \dots, n$ dan $j = 1, 2, \dots, p$.

Informasi yang dihasilkan oleh *forget gate*, *input gate*, dan *candidate memory cell* digabungkan dengan menggunakan *hadamard product* dan penjumlahan pada persamaan (5). Pada *output gate*, *hidden state* dari sel sebelumnya dan *input* saat ini diproses dengan fungsi sigmoid. *Memory cell* yang baru kemudian diproses melalui fungsi tanh. Hasil dari fungsi tanh akan dikalikan dengan hasil dari fungsi sigmoid untuk memperoleh informasi yang akan disimpan pada *hidden state* yang baru. *Hidden state* dan *memory cell* yang baru kemudian akan diteruskan ke sel selanjutnya. Proses pada *output gate* dapat digambarkan pada persamaan (6) dan (7) [14].

$$\mathbf{C}_t = \mathbf{F}_t \odot \mathbf{C}_{t-1} + \mathbf{I}_t \tilde{\mathbf{C}}_t \quad (5)$$

dengan

- $\mathbf{C}_t \in \mathbb{R}^{n \times p}$: matriks *memory cell* pada *time step* t ;
 $\mathbf{F}_t \in \mathbb{R}^{n \times p}$: matriks *forget gate* pada *time step* t ;
 \odot : operasi *Hadamard product*;
 $\mathbf{I}_t \in \mathbb{R}^{n \times p}$: matriks *input gate* pada *time step* t ;
 $\tilde{\mathbf{C}}_t \in \mathbb{R}^{n \times p}$: matriks *candidate memory cell* pada *time step* t .

$$\mathbf{O}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xo} + \mathbf{H}_{t-1} \mathbf{W}_{ho} + \mathbf{B}_o) \quad (6)$$

dengan

- $\mathbf{O}_t \in \mathbb{R}^{n \times p}$: matriks *output gate* pada *time step* t ;
 σ : fungsi aktivasi sigmoid
 $\mathbf{X}_t \in \mathbb{R}^{n \times d}$: matriks *input* pada *time step* t ;
 $\mathbf{W}_{xo} \in \mathbb{R}^{d \times p}$: matriks bobot yang menghubungkan *input node* (x) dengan *output gate* (o) pada *time step* t ;
 $\mathbf{H}_{t-1} \in \mathbb{R}^{n \times p}$: matriks *hidden state* pada *time step* $t - 1$;
 $\mathbf{W}_{ho} \in \mathbb{R}^{p \times p}$: matriks bobot yang menghubungkan *hidden node* (h) pada *time step* $t - 1$ dengan *output gate* (o) pada *time step* t ;
 $\mathbf{B}_o \in \mathbb{R}^{n \times p}$: matriks parameter bias pada *output gate* *time step* t dan $\mathbf{B}_o = [b_{ij}]$ dengan $b_{ij} = b_{kj}$ untuk setiap $i, k = 1, 2, \dots, n$ dan $j = 1, 2, \dots, p$.

$$\mathbf{H}_t = \mathbf{O}_t \odot \tanh(\mathbf{C}_t) \quad (7)$$

dengan

- $\mathbf{H}_t \in \mathbb{R}^{n \times p}$: matriks *hidden state* pada *time step* t ;
 $\mathbf{O}_t \in \mathbb{R}^{n \times p}$: matriks *output gate* pada *time step* t ;



\tanh : fungsi aktivasi \tanh
 $C_t \in \mathbb{R}^{n \times p}$: matriks *memory cell* pada *time step* t .

2.5. Denormalisasi

Denormalisasi data merupakan proses pengembalian nilai yang telah dilakukan normalisasi menjadi nilai aktual. Denormalisasi data dapat membantu mempertahankan informasi penting dan meningkatkan kinerja model *neural network*. Proses denormalisasi data dapat dilakukan menggunakan persamaan (8)[7].

$$v = v'(\max(x) - \min(x)) + \min(x), \quad (8)$$

2.6. Metrik Evaluasi

Metrik evaluasi model diperlukan untuk mengukur performa model. Metode yang dapat digunakan untuk mengevaluasi model regresi adalah *mean absolute percentage error* (MAPE). Metode MAPE adalah pengukuran kesalahan yang dilakukan dengan menghitung persentase penyimpangan antara data sebenarnya dengan data hasil prediksi (Anggrainingsih dkk., 2015). Metode MAPE dapat digunakan untuk menganalisis kumpulan data yang memiliki nilai besar karena memberikan representasi kesalahan relatif dalam prediksi. Secara matematis, MAPE dapat dihitung menggunakan persamaan (9) [4].

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%, \quad (9)$$

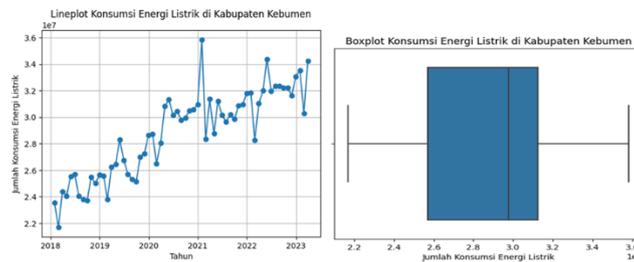
Tabel 2. Kriteria nilai MAPE

Nilai MAPE	Akurasi
$MAPE \leq 10\%$	Tinggi
$10\% < MAPE \leq 20\%$	Baik
$20\% < MAPE \leq 50\%$	<i>Reasonable</i>
$MAPE > 50\%$	Rendah

III. HASIL DAN PEMBAHASAN

Tahap pertama yang dilakukan dalam penelitian ini adalah eksplorasi dan analisis data dilakukan untuk mengetahui karakteristik data, mengidentifikasi pola, deteksi anomali, dan mengungkap informasi menarik dari data. Data yang diperoleh perlu diperiksa untuk mengetahui karakteristik data, mengidentifikasi pola, deteksi anomali, dan mengungkap informasi menarik dari data. Data juga perlu diperiksa adanya nilai kosong (*missing values*) dan nilai duplikat (*duplicated values*). Pemeriksaan nilai kosong dan nilai duplikat dapat dilakukan menggunakan fungsi *isnull()* dan fungsi *duplicated()*. Berdasarkan kedua fungsi tersebut, data tidak memiliki nilai kosong maupun nilai duplikat.

Selanjutnya dilakukan visualisasi data untuk menemukan pola data atau informasi tambahan dari data. Visualisasi yang digunakan yaitu *line plot* dan *box plot*. Hasil visualisasi dapat dilihat pada Gambar 2. Pada visualisasi *line plot*, data mengalami fluktuasi, tetapi secara keseluruhan data cenderung naik sehingga dapat dikatakan data memiliki *trend* naik. Berdasarkan visualisasi *box plot*, data tidak memiliki *outlier* sehingga data dapat dilanjutkan ke tahap persiapan data.



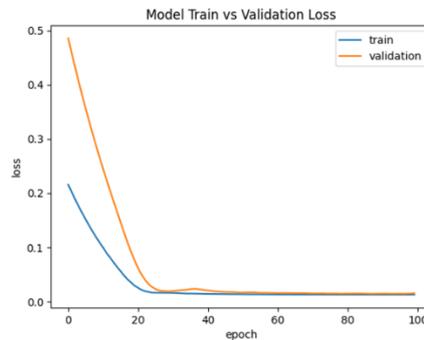
(a) (b)
Gambar 2. Visualisasi *line plot* (a) dan *box plot* (b)

Pada tahap persiapan data, data diubah menjadi *array* dua dimensi dengan 63 baris dan 1 kolom yang berisi data konsumsi energi listrik dalam kWh. Pada *array* tersebut dilakukan normalisasi data menggunakan fungsi *MinMaxScaler*. Selanjutnya, *array* yang telah dinormalisasi dibuat data urutan (*sequences data*) yang akan digunakan untuk proses prediksi. Hasil *sequences data* dapat dilihat pada Gambar 3.

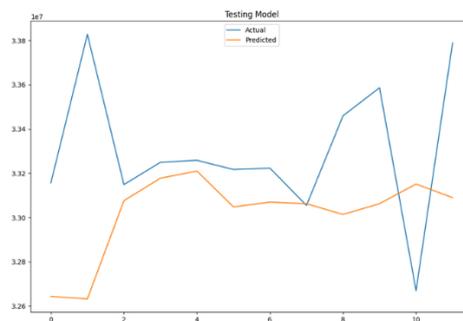
Sequences data dibagi menjadi data latih dan data uji dengan proporsi 80% untuk data latih dan 20% untuk data uji. Data tersebut diubah ke bentuk tiga dimensi dilakukan menggunakan fungsi *reshape()* agar dapat dilakukan proses *training* pada metode LSTM. Proses *training* tersebut dapat dilihat pada Gambar 4. Pada Gambar 4 tersebut, nilai *train* dan *validation loss* terus menurun dan mulai stabil pada *epoch* ke 45. Dengan demikian, performa model saat melakukan *training* sudah baik atau *good fit*. Pada penelitian ini, hasil prediksi konsumsi energi listrik di Kabupaten Kebumen yang menggunakan metode *long short-term memory* (LSTM) dievaluasi dengan membandingkannya dengan data sebenarnya, Perbandingan visualisasi kedua data tersebut dapat dilihat pada Gambar 5. Metode evaluasi yang digunakan adalah *mean absolute percentage error* (MAPE). Nilai MAPE yang diperoleh adalah 4,07%. Berdasarkan kriteria nilai MAPE pada Tabel 1, nilai 4,07% termasuk dalam kategori akurasi tinggi. Dengan demikian dapat diketahui bahwa model sudah cukup baik untuk melakukan prediksi.

Tabel 3. Hasil *sequences data*

<i>Sequences Data</i>			
0,13048705	0	0,18929273	0,16782321
0	0,18929273	0,16782321	0,27102967
0,18929273	0,16782321	0,27102967	0,28103297
0,16782321	0,27102967	0,28103297	0,16611262
0,27102967	0,28103297	0,16611262	0,14801858
0,28103297	0,16611262	0,14801858	0,14230832
0,16611262	0,14801858	0,14230832	0,26774007
0,14801858	0,14230832	0,26774007	0,23340228
0,14230832	0,26774007	0,23340228	0,27833862
0,26774007	0,23340228	0,27833862	0,27490153
0,23340228	0,27833862	0,27490153	0,14885754
0,27833862	0,27490153	0,14885754	0,32120643
0,27490153	0,14885754	0,32120643	0,33647215
0,14885754	0,32120643	0,33647215	0,46636451
0,32120643	0,33647215	0,46636451	0,35706763
0,33647215	0,46636451	0,35706763	0,28339032
0,46636451	0,35706763	0,28339032	0,25666587
0,35706763	0,28339032	0,25666587	0,24329629
0,28339032	0,25666587	0,24329629	0,37558398
0,25666587	0,24329629	0,37558398	0,39208337
0,24329629	0,37558398	0,39208337	0,49208285
0,37558398	0,39208337	0,49208285	0,49605939



Gambar 4. Visualisasi training model



Gambar 5. Perbandingan visualisasi hasil prediksi konsumsi energi listrik dengan data sebenarnya

Proses prediksi pada model LSTM dilakukan dengan fungsi *predict()*. Hasil data prediksi masih berupa data yang dinormalisasi sehingga perlu diubah ke bentuk aslinya. Pengubahan data ke bentuk aslinya dilakukan dengan fungsi *invers_transform()*. Hasil data prediksi dapat dilihat pada Tabel 2. Dengan demikian, total konsumsi energi listrik pada tahun 2023 di Kabupaten Kebumen adalah berkisar 389.856.088 kWh.

Tabel 4. Hasil prediksi konsumsi energi listrik di Kabupaten Kebumen pada bulan April – Desember 2023

Normalisasi	Denormalisasi
0,54394950	32.424.104
0,46449190	32.108.036
0,66781000	32.916.792
0,53009903	32.369.006
0,53540020	32.390.094
0,56477020	32.506.924
0,52846490	32.362.508
0,53254586	32.378.740
0,53352330	32.382.630

IV. KESIMPULAN

Metode LSTM dapat digunakan untuk memprediksi konsumsi energi Listrik di Kabupaten Kebumen. Proses prediksi menggunakan metode LSTM pada *google colab* perlu melalui beberapa tahap, yaitu pengumpulan data, eksplorasi dan analisis data, persiapan data numerik, pembuatan kode program metode LSTM, visualisasi *training* model, evaluasi terhadap model LSTM, dan pembuatan prediksi berdasarkan data historis. Pengerjaan tahap-tahap tersebut dilakukan secara



berurutan sehingga apabila terjadi kesalahan pada salah satu tahap, maka tahap selanjutnya tidak dapat dikerjakan dan perlu memeriksa tahap sebelumnya.

Evaluasi model LSTM dilakukan menggunakan metode MAPE. Hasil evaluasi tersebut menunjukkan nilai MAPE sebesar 4,07%. Berdasarkan kriteria nilai MAPE, nilai tersebut termasuk dalam kategori akurasi tinggi sehingga model layak digunakan untuk prediksi. Hasil prediksi menunjukkan bahwa jumlah konsumsi energi listrik di Kabupaten Kebumen pada tahun 2023 adalah berkisar 389.856.088 kWh. Jumlah tersebut mengalami kenaikan dibandingkan dengan tahun sebelumnya, yaitu 383.251.784 kWh.

REFERENSI

1. Ahmad, A. S., Hassan, M. Y., Abdullah, M. P., Rahman, H. A., Hussin, F., Abdullah, H., & Saidur, R. (2014). A Review on Applications of ANN and SVM for Building Electrical Energy Consumption Forecasting. *Renewable and Sustainable Energy Reviews*, 33, 102-109.
2. Anggrainingsih, R., Aprianto, G.R., & Sihwi, S.W. (2015). Time Series Forecasting Using Exponential Smoothing to Predict the Number of Website Visitor of Sebelas Maret University. *2015 2nd International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)*, 14-19.
3. Brownlee, J. (2017). *Long Short-Term Memory Networks with Python: Develop Sequence Prediction Models with Deep Learning*. Machine Learning Mastery.
4. Chooruang, K.; Tongta, A., & (2020). Long Short-Term Memory (LSTM) Neural Networks Applied to Energy Disaggregation. In *2020 8th International Electrical Engineering Congress (iEECON) (pp. 1-4)*. IEEE.
5. Divina, F., Gilson, A., Gómez-Vela, F., García Torres, M., & Torres, J. F. (2018). Stacking Ensemble Learning for Short-Term Electricity Consumption Forecasting. *Energies*, 11(4), 949.
6. Ekananta, Y., Muflikhah, L., & Dewi, C. (2018). Penerapan Metode Average-Based Fuzzy Time Series Untuk Prediksi Konsumsi Energi Listrik Indonesia. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(3), 1283-1289.
7. Fahrizal, M. A., Adinugroho, S., & Wihandika, R. C. (2021). Prediksi Volume Penggunaan Air Bulanan Kota Batu Menggunakan Metode Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5(7), 3078-3086.
8. Finata, R. (2015). Prakiraan Konsumsi Energi Listrik di Sumatera Utara Pada Tahun 2025 Menggunakan Metode Regresi Dalam Aplikasi Simple E. *Tugas Akhir UMSU*.
9. Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*, 11(7), 1387.
10. Nugraha, Y. T., Zambak, M. F., & Hasibuan, A. (2020). Perkiraan Konsumsi Energi Listrik di Aceh Pada Tahun 2028 Menggunakan Metode Adaptive Neuro Fuzzy Inference System. *Cess (Journal of Computer Engineering, System and Science)*, 5(1), 104-108.
11. Rahman, A. (2015). Prakiraan Dan Analisa Kebutuhan Energi Listrik Provinsi Sumatera Barat Hingga Tahun 2024 dengan Metode Analisis Regresi Linear Berganda. *Jurnal Teknik Elektro*, 4(2), 34-43.
12. Somu, N., MR, G. R., & Ramamritham, K. (2020). A Hybrid Model for Building Energy Consumption Forecasting Using Long Short-Term Memory Networks. *Applied Energy*, 261, 114131.
13. Syafruddin, M. L. H. D. D., Hakim, L., & Despa, D. (2014). Metode Regresi Linier Untuk Prediksi Kebutuhan Energi Listrik Jangka Panjang (Studi Kasus Provinsi Lampung). *Jurnal Informatika dan Teknik Elektro Terapan*, 2(2).
14. Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2023). *Dive Into Deep Learning*. Cambridge University Press.
15. Zheng, J., Xu, C., Zhang, Z., & Li, X. (2017). Electric Load Forecasting in Smart Grids Using Long Short-Term Memory Based Recurrent Neural Network. In *2017 51st Annual conference on information sciences and systems (CISS) (pp. 1-6)*. IEEE.