

## PREDIKSI TOTAL TAGIHAN LISTRIK PELANGGAN TARIF P1 ULP SUKADANA MENGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM)

**Rida Fitriani**

Program Studi Matematika, Fakultas Sains, Institut Teknologi Sumatera, Lampung, Indonesia;  
rida.122160013@student.itera.ac.id

**Werry Febrianti\***

Program Studi Matematika, Fakultas Sains, Institut Teknologi Sumatera;  
werry.febrianti@ma.itera.ac.id

### Abstrak

Penelitian ini bertujuan untuk memprediksi total tagihan listrik pelanggan tarif P1 di Unit Layanan Pelanggan (ULP) Sukadana menggunakan metode *Long Short-Term Memory* (LSTM). Pada penelitian ini, data yang digunakan merupakan data historis bulanan dari Januari 2023 hingga Juni 2025 yang mencakup pemakaian energi (kWh), jam nyala, daya, jam kerja, dan total tagihan. Proses penelitian meliputi pengumpulan data, pemisahan data menjadi data latih dan uji, penentuan parameter, pelatihan model, tuning, serta evaluasi menggunakan *Mean Absolute Percentage Error* (MAPE). Hasil tuning menunjukkan konfigurasi terbaik pada unit LSTM sebanyak 56, unit *dense* 12, dan *learning rate* 0.1. Model menghasilkan nilai MAPE sebesar 2,89% untuk data latih dan 5,81% untuk data uji, yang dikategorikan sangat akurat. Model ini kemudian digunakan untuk memprediksi tagihan listrik bulan Juli 2025, dengan hasil estimasi sebesar Rp433.344.576,00. Hasil penelitian menunjukkan bahwa metode LSTM mampu mengenali pola data deret waktu secara efektif dan dapat digunakan sebagai alat bantu untuk estimasi tagihan listrik yang lebih akurat, serta mendukung pengambilan keputusan dalam perencanaan operasional di lingkungan PLN UP3 Metro.

**Kata Kunci:** Prediksi, Tagihan Listrik, *Long Short-Term Memory* (LSTM), *Mean Absolute Percentage Error* (MAPE), PLN (Persero) UP3 Metro.

### Abstract

*This study aims to predict the total electricity bills of P1 tariff customers at the Sukadana Customer Service Unit (ULP) using the Long Short-Term Memory (LSTM) method. In this study, the data used is historical monthly data from January 2023 to June 2025, which includes energy consumption (kWh), hours of use, power, working hours, and total bills. The research process includes data collection, separation of data into training and test data, parameter determination, model training, tuning, and evaluation using Mean Absolute Percentage Error (MAPE). The tuning results showed the best configuration in 56 LSTM units, 12 Dense units, and a learning rate of 0.1. The model produced a MAPE value of 2.89% for training data and 5.81% for test data, which was categorized as highly accurate. This model was then used to predict the electricity bill for July 2025, with an estimated result of IDR 433,344,576.00. The results of this study show that the LSTM method is capable of effectively recognizing time series data patterns and can be used as a tool for more accurate electricity bill estimates, as well as supporting decision-making in operational planning at PLN UP3 Metro.*

**Keywords:** Forecast, Electricity Bills, Long Short-Term Memory (LSTM), Mean Absolute Percentage Error (MAPE), PLN (Persero) UP3 Metro.

## PENDAHULUAN

PT PLN (Persero) bertanggung jawab sebagai penyedia utama tenaga listrik di Indonesia. Salah satu unit operasionalnya, Unit Pelaksana Pelayanan Pelanggan (UP3) Metro, memiliki peran penting dalam pelayanan pelanggan terkait energi listrik. ULP Sukadana sebagai bagian dari UP3 Metro, melayani pelanggan dengan berbagai golongan tarif, termasuk pelanggan tarif P1 (Isnaini et al., 2022). Pelanggan tarif P1 mencakup kantor pemerintahan kecil dan pelanggan industri dengan daya listrik yang bervariasi, mulai 450 VA hingga 200kVA (Firdaus et al., 2022).

Pelanggan dengan tarif P1 memiliki pola konsumsi listrik yang cukup tinggi dan fluktuatif. Fluktuasi ini menyulitkan perhitungan tagihan menggunakan metode konvensional. Tagihan yang tidak akurat dapat berdampak pada pendapatan PLN dan kepuasan pelanggan. Berdasarkan hal tersebut, diperlukan metode yang lebih canggih untuk memprediksi total tagihan listrik dengan lebih tepat (Hariatin & Sugijanto, 2021).

Penelitian ini mengusulkan penggunaan metode *Long Short-Term Memory* (LSTM) dalam jaringan saraf tiruan (JST) yang dirancang khusus untuk menangani data berurutan atau *time series* (Ardesfira et al., 2022). LSTM telah terbukti efektif dalam memodelkan pola konsumsi yang fluktuatif dan kompleks. Penggunaan data historis konsumsi listrik, model LSTM diharapkan mampu memberikan prediksi tagihan listrik yang lebih akurat.

Penelitian ini bertujuan untuk membangun model prediksi tagihan listrik berbasis LSTM menggunakan pemrograman Python. Evaluasi akurasi model dilakukan dengan metrik *Mean Absolute Percentage Error* (MAPE), yang mengukur perbedaan antara nilai aktual dan nilai prediksinya (Maricar, 2019). Harapannya, model ini dapat memberikan kontribusi dalam meningkatkan efisiensi operasional PLN serta mendukung perencanaan pendapatan yang lebih baik.

Berbagai penelitian sebelumnya telah dilakukan terkait prediksi konsumsi maupun pembayaran listrik. Penelitian oleh Utami & Arifyanto (2025) berfokus pada prediksi keterlambatan pembayaran tagihan listrik menggunakan algoritma Random Forest dan Bidirectional LSTM, namun penelitian ini

hanya menekankan aspek keterlambatan, bukan jumlah nominal tagihan yang harus dibayarkan pelanggan. Penelitian Fadilah, Yusuf, & Huda (2020) menggunakan Jaringan Saraf Tiruan (*Backpropagation*) untuk memprediksi beban listrik di Kota Banjarbaru, tetapi akurasinya menurun signifikan ketika terjadi perubahan pola konsumsi ekstrem sehingga kurang adaptif terhadap data listrik yang fluktuatif. Penelitian Zalmi, Pang, & Nurgraha (2024) mengimplementasikan logika fuzzy Mamdani untuk memperkirakan biaya pemakaian listrik berdasarkan golongan tarif dan kapasitas daya. Walaupun mudah dipahami, metode ini tidak memanfaatkan data historis jangka panjang sehingga tidak mampu menangkap dinamika pola konsumsi pelanggan dari waktu ke waktu. Penelitian Rumagit & Azhari (2010) membandingkan metode ARIMA, JST, dan gabungan keduanya dalam memprediksi pemakaian listrik di wilayah Sullutenggo. Akan tetapi, data yang digunakan relatif lama (2004–2010) dan belum mencerminkan kondisi konsumsi listrik saat ini yang semakin kompleks. Terakhir, penelitian Chasani & Zukhri (2013) mengembangkan aplikasi prediksi tagihan listrik berbasis JST, tetapi hanya terbatas pada satu pelanggan dengan horizon prediksi satu bulan sehingga tidak cukup representatif untuk kebutuhan PLN dalam skala besar.

## KAJIAN TEORI

### Tagihan Listrik Pasca Bayar

Tagihan listrik pasca bayar adalah kewajiban finansial yang harus dibayarkan oleh pelanggan setelah penggunaan listrik (Andreani et al., 2024). Sistem ini memungkinkan pelanggan untuk menggunakan listrik terlebih dahulu dan membayar tagihan pada bulan berikutnya (Yusuf et al., 2023). Perhitungan tagihan listrik dipengaruhi oleh faktor daya listrik, durasi pemakaian, dan tarif listrik per kWh. Biaya tambahan, seperti denda dan administrasi, juga tercakup dalam tagihan. Keakuratan perhitungan penting agar PLN dapat menjaga kepuasan pelanggan dan memastikan pendapatan yang sesuai dengan konsumsi yang tercatat. Besarnya tagihan dan pemKWh dapat diketahui berdasarkan persamaan (1) dan (2).

$$\text{Tagihan (Rp)} = \text{PemKWh} \times \text{tarif(Rp/kWh)} + \text{biaya eksternal} \quad (1)$$

$$\text{PemkWh} = \frac{\text{Daya}}{1000} \times \text{jam nyala} \quad (2)$$

### Pelanggan Tarif P1

Pelanggan tarif P1 terdiri dari kantor pemerintahan kecil dan sedang yang menggunakan listrik pada tegangan rendah dengan daya 450 VA hingga 200 kVA (Widayat, 2017). Golongan ini memiliki konsumsi listrik yang fluktuasi, menyulitkan prediksi tagihan secara akurat. Tarif listrik untuk golongan ini ditetapkan Rp 1.699,53/kWh. Besarnya kontribusi pelanggan tarif P1 terhadap PLN menjadikan prediksi tagihan yang akurat penting untuk pengelolaan yang efisien.

### Deret Waktu (Time Series)

Deret waktu merupakan kumpulan data yang disusun berdasarkan urutan waktu, seperti harian, bulanan, dan tahunan. Data konsumsi pelanggan dicatat dalam periode tertentu dan digunakan untuk mengidentifikasi pola serta variasi dalam penggunaan listrik (Pangaribuan et al., 2023). Analisis deret waktu memungkinkan PLN untuk memperkirakan konsumsi dan tagihan listrik di masa depan, yang bermanfaat untuk perencanaan dan pengambilan keputusan yang lebih tepat.

### Prediksi

Teknik memprediksi nilai dimasa depan suatu variabel dengan menggunakan data historis atau data sebelumnya sebagai dasar dikenal sebagai prediksi (Adiguno et al., 2022). Data yang umum digunakan dalam proses prediksi adalah data kuantitatif. Prediksi sendiri tidak bertujuan untuk memberikan hasil yang sepenuhnya pasti, melainkan untuk mendekati kemungkinan dimasa depan seakurat mungkin berdasarkan data yang tersedia.

### Fungsi Aktivasi

Fungsi aktivasi adalah fungsi yang digunakan untuk memutuskan apakah suatu sel saraf dapat diaktifkan atau tidak. Fungsi ini memanipulasi data yang disajikan melalui beberapa pemrosesan gradien dan kemusian menghasilkan keluaran untuk jaringan saraf (Kurniawan et al., 2024). Metode LSTM menggunakan dua fungsi aktivasi yaitu fungsi aktivasi sigmoid dan fungsi aktivasi *tanh*. Persamaan fungsi aktivasi sigmoid ditunjukkan oleh persamaan

(3) dan fungsi aktivasi *tanh* ditunjukkan pada persamaan (4).

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

Keterangan:

$\sigma(x)$  : fungsi aktivasi sigmoid


$\text{Tanh}(x)$  : fungsi aktivasi tangen hiperbolik

$e$  : konstanta euler (2,71828)

$x$  : nilai *input* atau masukan

### Long Short-Term Memory (LSTM)

LSTM merupakan tipe jaringan saraf tiruan yang dirancang khusus untuk menangani data deret waktu (Sianturi et al., 2023). Metode ini mampu mengatasi masalah *vanishing gradient* yang sering terjadi pada *Recurrent Neural Network* (RNN). LSTM memiliki dua komponen utama yaitu *cell state* (memori jangka panjang) dan *hidden state* (memori jangka pendek). Proses *hidden state* pada *Long Short-Term Memory* (LSTM) melalui 3 gate yaitu *forget gate*, *input gate*, dan *output gate* (Cahyani et al., 2023).



Gambar 1. Arsitektur LSTM

(sumber : ietresearch.onlinelibrary.wiley.com)

Setiap *gate* menggunakan nilai masukan  $x_t$  dan nilai *hidden state* pada *time step* sebelumnya  $h_{t-1}$  dengan nilai bobot dan bias yang ditentukan oleh model.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c[s_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (10)$$

Keterangan:

- $f_t$  : nilai *forget gate*  
 $i_t$  : nilai *input gate*  
 $\tilde{C}_t$  : nilai kandidat *cell state*  
 $C_t$  : nilai *cell state*  
 $o_t$  : nilai *output gate*  
 $h_t$  : nilai *hidden state*  
 $W_{f,i,c,o}$  : nilai bobot pada *forget gate*, *input gate*, kandidat *cell state*, *output gate*.  
 $b_{f,i,c,o}$  : nilai bias pada *forget gate*, *input gate*, kandidat *cell state*, *output gate*.  
 $x_t$  : nilai masukan  
 $h_{t-1}$  : nilai *hidden state* sebelumnya  
 $\tanh()$  : fungsi aktivasi tanh  
 $\sigma()$  : fungsi aktivasi sigmoid

#### Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah salah satu metrik evaluasi akurasi model prediksi salah satunya prediksi tagihan listrik (Ngabidin et al., 2023). Mean Absolute Percentage Error (MAPE) mengukur persentase kesalahan rata-rata antara nilai aktual (asli) dan nilai hasil prediksi. semakin kecil nilai Mean Absolute Percentage Error (MAPE), maka semakin akurat model tersebut. Berikut persamaan mencari nilai Mean Absolute Percentage Error (MAPE).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (11)$$

Keterangan:

- $A_t$  : nilai aktual pada waktu ke- $t$   
 $F_t$  : nilai hasil prediksi pada waktu ke- $t$   
 $n$  : jumlah data

Selain itu, untuk mengevaluasi performa model prediksi, digunakan metrik akurasi berupa Mean Absolute Percentage Error (MAPE). Interpretasi nilai MAPE disajikan pada tabel 1.

Tabel 1. Interpretasi Nilai MAPE

| Nilai MAPE (%)          | Interpretasi Akurasi |
|-------------------------|----------------------|
| $\leq 10\%$             | Sangat akurat        |
| $10\% < MAPE \leq 20\%$ | Baik                 |
| $20\% < MAPE \leq 50\%$ | Layak                |
| $> 50\%$                | Buruk (Tidak akurat) |

#### METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan data yang diperoleh dari Aplikasi Pelayanan Pelanggan Terpusat (AP2T) milik PT PLN (Persero) UP3 Metro. Data yang digunakan mencakup pemakaian energi listrik (kWh), daya terpasang, jam nyala, serta jam kerja pelanggan tarif P1 di Unit Layanan Pelanggan (ULP) Sukadana dengan rentang waktu dari Januari 2023 hingga Juni 2025. Data ini dipilih karena mencerminkan fluktuasi yang signifikan, terutama setelah pandemi dan masa pemulihan ekonomi. Untuk menghitung total jam kerja, data hari kerja dalam setiap bulan dikalikan dengan standar waktu kerja 8 jam/hari, karena faktor jam kerja juga memengaruhi besar tagihan listrik.


Data yang telah dikumpulkan kemudian diproses dengan memisahkan fitur input dan target output. Fitur *input* meliputi pemakaian kWh, jam nyala, daya, dan jam kerja, sementara target *output* adalah total tagihan listrik. Data selanjutnya diubah menjadi urutan histori (*sequence*) dengan jumlah *time steps* sebanyak 3 bulan sebelumnya untuk memprediksi tagihan listrik bulan berikutnya. Normalisasi data dilakukan dengan metode *StandardScaler* dan *Min-Max Normalization* untuk memastikan bahwa data berada dalam rentang yang sesuai untuk model LSTM.

Selanjutnya, data dipisahkan menjadi data latih (80%) dan data uji (20%). Pemisahan ini bertujuan untuk melatih model menggunakan data yang cukup, sementara data uji digunakan untuk menguji kinerja model. Pembagian 80:20 telah terbukti efektif dalam penelitian sebelumnya dan membantu menghindari *overfitting*, di mana model hanya mengingat data lama tanpa mampu memprediksi data baru dengan baik.

Setelah data diproses, model LSTM dibangun dengan menentukan parameter seperti *batch size*, *learning rate*, jumlah epoch, dan jumlah unit LSTM berdasarkan studi literatur. Arsitektur model terdiri dari *input layer*, *LSTM layer*, dan *output layer*. Model pertama kali dilatih dengan data latih dan dievaluasi menggunakan Mean Absolute Percentage Error (MAPE). Jika hasil MAPE menunjukkan akurasi yang rendah ( $< 10\%$ ), model dilanjutkan dengan *hyperparameter tuning*, yang melibatkan pencarian

kombinasi optimal dari parameter seperti *learning rate*, jumlah *neuron*, dan *epoch*.

Setelah tuning, model terbaik dilatih kembali dan diuji dengan data uji. Evaluasi akhir dilakukan berdasarkan hasil MAPE, dan model dengan nilai MAPE terkecil dipilih sebagai model prediksi terbaik. Model ini digunakan untuk memprediksi total tagihan listrik pelanggan pada bulan Juli 2025.



Gambar 2. Diagram Alir Penelitian


## HASIL DAN PEMBAHASAN

Penelitian ini menggunakan data historis total tagihan listrik bulanan dari 120 pelanggan tarif P1 yang tercatat di PLN ULP Sukadana. Data dicatat dalam bentuk deret waktu bulanan dari Januari 2023 hingga Juni 2025 atau sebanyak 30 bulan. Data yang digunakan meliputi: Total pemakaian energi (kWh), jam nyala, daya terpasang, estimasi jam kerja (8 jam/hari), dan total tagihan listrik per bulan. Puncak tagihan listrik tercatat pada November 2024 sebesar Rp533.000.000,00, kemudian menurun drastis pada awal tahun 2025. Data tersebut di tunjukkan pada Tabel 2.

Tabel 2. Data Historis Pelanggan Tarif P1 ULP Sukadana

| No | Bulan    | PemkWh | Jam Nyala | Jam Kerja | Daya    | Total Tagihan |
|----|----------|--------|-----------|-----------|---------|---------------|
| 1  | Jan-2023 | 245205 | 3527.61   | 168       | 2085307 | 416848500     |
| 2  | Feb-2023 | 256079 | 3637.53   | 160       | 2111972 | 435334300     |
| 3  | Mar-2023 | 236891 | 3365.37   | 168       | 2111722 | 402714700     |

|    |          |        |         |     |         |           |
|----|----------|--------|---------|-----|---------|-----------|
| 4  | Apr-2023 | 247498 | 3516    | 112 | 2111756 | 420746600 |
| 5  | Mei-2023 | 211249 | 3002.35 | 168 | 2110836 | 359123300 |
| 6  | Jun-2023 | 269873 | 3814.7  | 152 | 2122366 | 458784100 |
| 7  | Jul-2023 | 220814 | 3124.25 | 160 | 2120322 | 375383800 |
| :  | :        | :      | :       | :   | :       | :         |
| 30 | Jun-2025 | 253712 | 3189.87 | 144 | 2386101 | 431310400 |



Gambar 3. Data Total Tagihan Listrik Pelanggan ULP Sukadana

Sumber : Pemrograman Python google colab

Proses selanjutnya adalah pemisahan fitur input dan target output.  $X$  sebagai fitur input yang terdiri dari pemakaian kWh (PemkWh), jam nyala, daya, dan jam kerja.  $y$  sebagai fitur output yaitu total tagihan listrik pelanggan.

Selanjutnya adalah melakukan pemisahan data sebelum membagi urutan data 3 time steps dilakukan dengan rasio 80 : 20. Data training sebesar 80% dan data testing sebesar 20%. Setelah proses pemisahan data training dan testing dilakukan membuat urutan data historis (*sequence*). Hasil pembagian data dan pembuatan urutan data historis dapat dilihat pada tabel 3 dan tabel 4.

Tabel 3. Hasil Pembagian Data Latih

| Sequence | $X_{train}$                                                                                                                               | $y_{train}$ |
|----------|-------------------------------------------------------------------------------------------------------------------------------------------|-------------|
| 1        | $\begin{bmatrix} 24520, 3527.61, 2085307, \\ 168 \\ 256079, 3637.53, 2111972, \\ 160 \\ 236891, 3365.371, 2111722, \\ 168 \end{bmatrix}$  | 4207746600  |
| 2        | $\begin{bmatrix} 256079, 3637.53, 2111972, \\ 160 \\ 236891, 3365.371, 2111722, \\ 168 \\ 247498, 3526, 2111756, \\ 112 \end{bmatrix}$    | 359123300   |
| 3        | $\begin{bmatrix} 236891, 3365.371, 2111722, \\ 168 \\ 247498, 3526, 2111756, 112, \\ 211249, 3002.35, 2110836, \\ 168 \end{bmatrix}$      | 458784100   |
| ⋮        | ⋮                                                                                                                                         | ⋮           |
| 21       | $\begin{bmatrix} 284702, 3680.005, 2320937, \\ 160 \\ 274266, 3542.33, 2322759, \\ 184 \\ 314114, 4056.26, 2323178, \\ 176 \end{bmatrix}$ | 463146300   |

Tabel 4. Hasil Pembagian Data Uji

| Sequence | $X_{test}$                                                                                                                              | $y_{test}$ |
|----------|-----------------------------------------------------------------------------------------------------------------------------------------|------------|
| 1        | $\begin{bmatrix} [274266, 3542.33, 2322759, 184], \\ [314114, 4056.26, 2323178, 168], \\ [272439, 3494.55, 2338827, 160] \end{bmatrix}$ | 439062400  |
| 2        | $\begin{bmatrix} [314114, 4056.26, 2323178, 168], \\ [272439, 3494.55, 2338827, 160], \\ [258272, 3313.03, 2338690, 152] \end{bmatrix}$ | 401463500  |
| 3        | $\begin{bmatrix} [272439, 3313.03, 2338827, 160], \\ [258272, 3313.03, 2338690, 152], \\ [236155, 3029.22, 2378906, 160] \end{bmatrix}$ | 395149700  |
| ⋮        | ⋮                                                                                                                                       | ⋮          |
| 6        | $\begin{bmatrix} [232441, 2981.42, 2338897, 152], \\ [229896, 2899.18, 2338897, 128], \\ [230406, 2905.64, 2378886, 136] \end{bmatrix}$ | 431310400  |

Kemudian normalisasi data dengan *StandarScaler* (Z-Score). Proses normalisasi data dilakukan untuk memperoleh nilai memiliki skala yang seragam sehingga dapat digunakan dalam pemodelan LSTM. Berikut data hasil normalisasi data yang telah dilakukan.

Tabel 5. Hasil Normalisasi Data Latih

| Sequence | $X_{train} (Scaled)$ | $y_{train} (scaled)$ |
|----------|----------------------|----------------------|
|----------|----------------------|----------------------|

|    |                                                                                                                              |       |
|----|------------------------------------------------------------------------------------------------------------------------------|-------|
| 1  | $\begin{bmatrix} [-0.225, 0.37, -1.25, 0.47], \\ [0.28, 0.73, -0.95, 0.028], \\ [-0.61, -0.17, -0.95, 0.47] \end{bmatrix}$   | -0.27 |
| 2  | $\begin{bmatrix} [0.28, 0.73, -0.95, 0.028], \\ [-0.61, -0.17, -0.95, 0.47], \\ [-0.118, -0.33, -0.95, -2.66] \end{bmatrix}$ | -1.75 |
| ⋮  | ⋮                                                                                                                            | ⋮     |
| 21 | $\begin{bmatrix} [1.62, 0.88, 1.38, 0.028], \\ [1.23, 0.42, 1.4, 1.37], \\ [2.98, 2.14, 1.4, 0.47] \end{bmatrix}$            | 0.75  |

Tabel 6. Hasil Normalisasi Data Uji

| Sequence | $X_{test} (Scaled)$                                                                                                          | $y_{test} (scaled)$ |
|----------|------------------------------------------------------------------------------------------------------------------------------|---------------------|
| 1        | $\begin{bmatrix} [-0.225, 0.37, -1.25, 0.47], \\ [0.28, 0.73, -0.95, 0.028], \\ [-0.61, -0.17, -0.95, 0.47] \end{bmatrix}$   | 0.17                |
| 2        | $\begin{bmatrix} [0.28, 0.73, -0.95, 0.028], \\ [-0.61, -0.17, -0.95, 0.47], \\ [-0.118, -0.33, -0.95, -2.66] \end{bmatrix}$ | -0.73               |
| ⋮        | ⋮                                                                                                                            | ⋮                   |
| 21       | $\begin{bmatrix} [-0.82, -1.46, 1.58, -0.42], \\ [-0.94, -1.74, 2.02, -1.76], \\ [0.91, -1.71, 2.02, -1.31] \end{bmatrix}$   | -0.013              |

Penelitian ini berhasil mengembangkan model prediksi tagihan listrik pelanggan tarif P1 di ULP Sukadana menggunakan metode *Long Short-Term Memory* (LSTM). Model yang dibangun menggunakan data historis yang mencakup pemakaian energi listrik (kWh), jam nyala, daya terpasang, estimasi jam kerja, dan total tagihan listrik pelanggan dari Januari 2023 hingga Juni 2025. Evaluasi awal model menunjukkan hasil yang cukup baik dengan MAPE sebesar 2,46% pada data pelatihan dan 8,03% pada data uji. MAPE pada data pelatihan menunjukkan bahwa model berhasil mempelajari pola konsumsi listrik, namun hasil pada data uji menunjukkan adanya sedikit ketidaksesuaian prediksi terhadap data yang lebih bervariasi.

Proses *hyperparameter tuning* dilakukan untuk meningkatkan akurasi model dengan mencoba kombinasi parameter yang berbeda. Hasil dari tuning menunjukkan bahwa kombinasi unit LSTM 56 dan unit *dense* 12 menghasilkan nilai MAPE terkecil, yaitu 5,86%.


Tabel 7. Hasil Hyperparameter Tuning

| Jenis Data | Nilai MAPE (%) | Nilai MAPE (%) | Interpretasi  |
|------------|----------------|----------------|---------------|
| Data Latih | 2.46%          | 2.89%          | Sangat Akurat |
| Data Uji   | 8.03%          | 5.81%          | Sangat Akurat |

| Unit LSTM | Unit Dense | Rataan MAPE (%) | Unit LSTM | Unit Dense | Rataan MAPE (%) |
|-----------|------------|-----------------|-----------|------------|-----------------|
| 8         | 4          | 8.45            | 40        | 4          | 68.68           |
|           | 8          | 7.55            |           | 8          | 8.18            |
|           | 12         | 6.46            |           | 12         | 8.83            |
|           | 16         | 10.78           |           | 16         | 8.46            |
| 16        | 4          | 9.11            | 48        | 4          | 7.48            |
|           | 8          | 9.13            |           | 8          | 6.70            |
|           | 12         | 7.95            |           | 12         | 7.38            |
|           | 16         | 8.74            |           | 16         | 7.18            |
| 24        | 4          | 8.75            | 56        | 4          | 39.51           |
|           | 8          | 9.61            |           | 8          | 7.54            |
|           | 12         | 8.11            |           | 12         | <b>5.86</b>     |
|           | 16         | 8.22            |           | 16         | 7.73            |
| 32        | 4          | 9.49            | 64        | 4          | 8.85            |
|           | 8          | 8.88            |           | 8          | 6.94            |
|           | 12         | 9.05            |           | 12         | 7.77            |
|           | 16         | 7.76            |           | 16         | 6.71            |

Setelah tuning, model terbaik dilatih ulang dan diuji menggunakan data yang belum pernah dilihat sebelumnya. Hasilnya menunjukkan peningkatan signifikan dalam hal akurasi prediksi, dengan MAPE yang lebih rendah dibandingkan dengan model awal. Meskipun terdapat deviasi yang lebih besar pada beberapa titik data uji, secara keseluruhan model berhasil mengikuti tren fluktuasi tagihan listrik dengan baik, menandakan bahwa model cukup adaptif terhadap pola konsumsi yang tidak stabil.




Gambar 4. Perbandingan Data Setelah Tuning (Data Latih)

Tuning ini berhasil meningkatkan akurasi model, dengan nilai MAPE pada data uji menurun menjadi 5,81%, menunjukkan bahwa model kini lebih dapat menggeneralisasi data yang sebelumnya tidak terlihat.

Tabel 8. Perbandingan Nilai MAPE Sebelum dan Setelah Tuning

Prediksi untuk bulan Juli 2025 menunjukkan bahwa total tagihan listrik pelanggan tarif P1 di ULP Sukadana diperkirakan sebesar Rp433.344.576,00, yang menunjukkan kenaikan sekitar 0,47% dibandingkan dengan bulan Juni 2025 yang sebesar Rp431.310.400,00. Kenaikan ini masih dalam rentang fluktuasi historis, yang menunjukkan bahwa model dapat memprediksi tagihan listrik dengan cukup akurat meskipun ada sedikit peningkatan dalam konsumsi atau perubahan pola yang tidak terduga.



Gambar 5. Prediksi Total Tagihan Listrik Pelanggan Tarif P1 ULP Sukadana

Penelitian ini membuka peluang bagi PLN untuk memanfaatkan model prediksi ini dalam perencanaan operasional dan estimasi pendapatan, meskipun peningkatan lebih lanjut diperlukan untuk mengatasi fluktuasi yang lebih ekstrem dalam data konsumsi.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada PT PLN (Persero) UP3 Metro, khususnya Unit Layanan Pelanggan (ULP) Sukadana, atas izin dan dukungan yang diberikan dalam menyediakan data historis pelanggan tarif P1 yang digunakan dalam penelitian ini. Ucapan terima kasih juga disampaikan kepada Bapak Lukas Santoro, selaku Pembimbing Lapangan, yang telah memberikan arahan, dukungan, dan bimbingan yang sangat berharga selama proses penelitian.

Penulis juga mengucapkan terima kasih kepada Dr. Werry Febrianti, S.Pd., M.Si., selaku Dosen Pembimbing, yang dengan penuh kesabaran memberikan arahan, saran konstruktif, dan motivasi yang sangat membantu dalam penyelesaian penelitian ini. Ucapan terima kasih juga disampaikan kepada Program Studi Matematika dan Ketua Program Studi Matematika, atas dukungan serta fasilitas yang diberikan selama masa penelitian.

Terakhir, penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan kontribusi, baik langsung maupun tidak langsung, dalam kelancaran penelitian ini. Semoga penelitian ini dapat memberikan manfaat yang besar bagi perkembangan ilmu pengetahuan dan aplikasi di bidang prediksi energi listrik.

## PENUTUP

### SIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa metode *Long Short-Term Memory* (LSTM) efektif dalam memprediksi total tagihan listrik pelanggan tarif P1 di ULP Sukadana. Data historis menunjukkan adanya pola musiman yang konsisten, dengan peningkatan tagihan pada akhir tahun dan penurunan pada pertengahan tahun. Proses *hyperparameter tuning* yang dilakukan pada model LSTM berhasil meningkatkan akurasi prediksi, dengan nilai MAPE pengujian sebesar 5,81%, yang menunjukkan hasil yang sangat akurat. Prediksi untuk bulan Juli 2025 menghasilkan estimasi yang mendekati nilai aktual, yang menandakan bahwa LSTM cocok diterapkan untuk mendukung perencanaan operasional PLN..

## SARAN

Penerapan metode LSTM ini dapat diperluas untuk jenis pelanggan lainnya (seperti R1, B2, I3) guna mendukung manajemen prediksi beban dan pendapatan di seluruh unit PLN. Selain itu, penelitian lebih lanjut dengan menggunakan metode prediksi lain sangat disarankan untuk membandingkan hasil yang lebih baik. Penggunaan metode evaluasi yang bervariasi juga penting untuk meningkatkan pemahaman tentang kinerja model dan memastikan ketepatan prediksi dalam berbagai skenario.

## DAFTAR PUSTAKA

- Adiguno, S., Syahra, Y., & Yetri, M. (2022). Prediksi Peningkatan Omset Penjualan Menggunakan Metode Regresi Linier Berganda. *Jurnal Sistem Informasi Triguna Dharma (JURSI TGD)*, 1(4), 275. <https://doi.org/10.53513/jursi.v1i4.5331>
- Andreani, S., Ariansyah, A., & Barnianto, A. (2024). Rancang Bangun Aplikasi Monitoring Dokumen Tagihan Pada PT. Subur Sedaya Maju Berbasis Web. *Jurnal Minfo Polgan*, 13(2), 1362-1367. <https://doi.org/10.33395/jmp.v13i2.14062>
- Ardesfira, G., Zedha, H. F., Fazana, I., Rahmadhiyanti, J., Rahima, S., & Anwar, S. (2022). Peramalan Nilai Tukar Rupiah Terhadap Dollar Amerika Dengan Menggunakan Metode Autoregressive Integrated Moving Average (Arima). *Jambura Journal of Probability and Statistics*, 3(2), 71-84. <https://doi.org/10.34312/jjps.v3i2.15469>
- Cahyani, J., Mujahidin, S., & Fiqar, T. P. (2023). Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem Dan Teknologi Informasi (JustIN)*, 11(2), 346. <https://doi.org/10.26418/justin.v11i2.57395>
- Effendi, N. (2018). Penerapan Jaringan Syaraf Tiruan untuk Memprediksi Efektifitas Pembelajaran dengan E-Learning. *SATIN - Sains Dan Teknologi Informasi*, 4(1), 1-10. <https://doi.org/10.33372/stn.v4i1.295>
- El Ghazi, M., & Akin, N. (2023). Optimizing Deep LSTM Model through Hyperparameter Tuning for Sensor-Based Human Activity Recognition in Smart Home. *Informatica (Slovenia)*, 47(10), 109-122. <https://doi.org/10.31449/inf.v47i10.5268>
- Firdaus, A. H., Widiatmoko, H., Robiyan, A., Adinda, N. A. O., & Nurhayati, E. (2022). Dampak Kenaikan Tarif Dasar Listrik Terhadap Sektor Industri. 1, 1-17.

- [https://indef.or.id/wp-content/uploads/2023/03/012022\\_wp\\_indef.pdf](https://indef.or.id/wp-content/uploads/2023/03/012022_wp_indef.pdf)
- Hariatin, N. A., & Sugijanto. (2021). Analisis Perhitungan Biaya Tagihan Dan Akuntansi Penjualan Energi Listrik Pascabayar Dan Prabayar Pada Pt Pln Unit Pelaksana Pelayanan Pelanggan (Up3) Surabaya Barat. *Journal of Sustainability Business Research*, 2(1), 542–557.
- Ichsan Firmansyah, & B. Herawan Hayadi. (2022). Komparasi Fungsi Aktivasi Relu dan Tanh pada Multilayer Perceptron. *JIKO (Jurnal Informatika Dan Komputer)*, 6(2), 200–206.
- Isnaini, M., Umam, H., & Sanjaya, G. A. (2022). Analisa Risiko Kecelakaan Kerja Karyawan Pada Pekerjaan Dalam Keadaan Bertegangan Menggunakan Metode Hazard And Operability (HAZOP) (Studi Kasus: PT. PLN (Persero) UP3 Pekanbaru). *Sitekin*, 19(02), 161–171.
- Kurniatul Hidayah, A., & Eka Putra, R. (2025). Penerapan Metode Long Short Term Memory untuk Memprediksi Harga Beras di Indonesia. *Journal of Informatics and Computer Science (JINACS)*, 6(03), 720–729. <https://doi.org/10.26740/jinacs.v6n03.p720-729>
- Kurniawan, K., Ceasaro, B., & Sucipto, S. (2024). Perbandingan Fungsi Aktivasi Untuk Meningkatkan Kinerja Model LSTM Dalam Prediksi Ketinggian Air Sungai. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 10(1), 134. <https://doi.org/10.26418/jp.v10i1.72866>
- Lasijan, T. G., Santoso, R., & Hakim, A. R. (2023). Prediksi Harga Emas Dunia Menggunakan Metode Long-Short Term Memory. *Jurnal Gaussian*, 12(2), 287–295. <https://doi.org/10.14710/j.gauss.12.2.287-295>
- Maricar, M. A. (2019). Analisa Perbandingan Nilai Akurasi Moving Average dan Exponential Smoothing untuk Sistem Peramalan Pendapatan pada Perusahaan XYZ. *Jurnal Sistem Dan Informatika*, 13, 37–46.
- Mubarokh, M. F., Nasir, M., & Komalasari, D. (2020). Jaringan Syaraf Tiruan Untuk Memprediksi Penjualan Pakaian Menggunakan Algoritma Backpropagation. *Journal of Computer and Information Systems Ampera*, 1(1), 29–43. <https://doi.org/10.51519/journalcisa.v1i1.3>
- Ngabidin, Z., Sanwidi, A., & Arini, E. R. (2023). Implementasi Metode Double Exponential Smoothing Brown Untuk Meramalkan Jumlah Penduduk Miskin. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(2), 328–338. <https://doi.org/10.37905/euler.v11i2.23054>
- Pangaribuan, J. J., Fanny, F., Barus, O. P., & Romindo, R. (2023). Prediksi Penjualan Bisnis Rumah Properti Dengan Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA). *Jurnal Sistem Informasi Bisnis*, 13(2), 154–161. <https://doi.org/10.21456/vol13iss2pp154-161>
- Pradana, D., Luthfi Alghifari, M., Farhan Juna, M., & Palaguna, D. (2022). Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network. *Indonesian Journal of Data and Science*, 3(2), 55–60. <https://doi.org/10.56705/ijodas.v3i2.35>
- Ramadhan, M. M., Sitanggang, I. S., Nasution, F. R., & Ghifari, A. (2017). Parameter Tuning in Random Forest Based on Grid Search Method for Gender Classification Based on Voice Frequency. *DEStech Transactions on Computer Science and Engineering*, cece. <https://doi.org/10.12783/dtcse/cece2017/14611>
- Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtjias, H. P. A., Yustanti, W., & Prihanto, A. (2021). Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam. *Journal of Information Engineering and Educational Technology*, 5(2), 44–48. <https://doi.org/10.26740/jieet.v5n2.p44-48>
- Sianturi, T. B., Cholissodin, I., & Yudistira, N. (2023). Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 7(3), 1101–1107. <http://j-ptiik.ub.ac.id>
- Suahati, A. F., Nurrahman, A. A., & Rukmana, O. (2022). Penggunaan Jaringan Syaraf Tiruan – Backpropagation dalam Memprediksi Jumlah Mahasiswa Baru. *Jurnal Media Teknik Dan Sistem Industri*, 6(1), 21. <https://doi.org/10.35194/jmtsi.v6i1.1589>
- Wahyuni, E., & HS, M. D. (2021). Pelaksanaan Tugas-tugas Sekretaris pada Bidang Administrasi dan Fasilitas di PT PLN (PERSERO) Wilayah Aceh. *Jurnal Ekonomi Manajemen Dan Sekretari*, 6(2), 37–41.
- Widayat, P. (2017). Resiko Keuangan Rumah Tangga Pasca Kenaikan Tarif Dasar Listrik (Studi Pada Masyarakat Kota Pekanbaru). 1, 2588–2593.
- Yusuf, S. B., Risal, M., Affandy, A. L., Arsianto, A., & Sawawi, M. (2023). Kontrol Penggunaan Listrik Pascabayar Menggunakan Android. *Jurnal It*, 13(2), 82–95. <https://doi.org/10.37639/jti.v13i2.349>