

Penerapan *Long Short Term Memory* untuk Peramalan Beban Listrik pada Gedung Bertingkat

Ony Ramadhan Armanto^{a,*}, Masyitah Aulia^a, Aulidina Dwi Nur Andriyanti^b

^a Fakultas Sains dan Teknologi, Universitas Teknologi Surabaya, Jl. Balongsari Praja V no 1, Surabaya, 60188, Indonesia
E-mail: Ony.ramadhan@utssurabaya.ac.id, Masyitah.aulia@utssurabaya.ac.id, Aulidina.dwi@utssurabaya.ac.id

*Corresponding Author: Ony.ramadhan@utssurabaya.ac.id

Abstract— In electric power operations, the use of energy often leads to decreased energy efficiency. Some of the main causes of power load instability are due to sudden changes or shifts, which cause the fluctuation of electrical energy to become imbalanced. If this instability persists over a long period, it poses a risk to the electrical system and can damage components. To prevent this, a load forecasting method is employed to determine the loading for a specific period. Electric energy forecasting is frequently used to determine the loading parameters that will occur in the future. This is done to maintain the quality of the electric power and ensure adequate energy supply. To provide accurate electric energy forecasting, several methods are often used, one of which is the artificial neural network (ANN). An ANN can use parameters not only derived from electrical measurements and main loading but also allows for non-linear computations. There are several ANN methods, one of which is Long Short-Term Memory (LSTM). Long Short-Term Memory is used when the input parameters are non-linear or uncorrelated. Therefore, to obtain maximum forecasting results, electric energy forecasting using Long Short-Term Memory was employed for a high-rise building. The research results then showed that a learning rate of 0.1 yielded an MAPE (Mean Absolute Percentage Error) of 6.43% and an RMSE (Root Mean Square Error) of 9.4.

Keywords— Long – Short Term Memory, Electrical Forecasting, Artificial Neural Network, Management Energy

Abstrak— Dalam operasi tenaga listrik penggunaan energi sering sekali menyebabkan efisiensi energi berkurang. Beberapa penyebab utama ketidakstabilan beban listrik dikarenakan perbuahan atau pergantian sewaktu waktu yang menyebabkan fluktuasi energi listrik menjadi tidak seimbang. Ketidakstabilan tersebut jika dalam kurun waktu yang lama beresiko kedalam sistem kelistrkan dan merusak komponen. Untuk mencegah hal tersebut dilakukan sebuah metode peramalan beban agar dapat mengetahui pembebanan pada periode tertentu. Peramalan energi listrik sering digunakan untuk mengetahui parameter pembebanan yang akan terjadi dimasa depan. Hal ini dilakukan agar menjaga kualitas daya listrik tetap terjaga dan energi yang mumpuni. Agar tetap memberikan peramalan energi listrik yang akurat ada beberapa metode yang sering digunakan salah satunya menggunakan jaringan syaraf tiruan. Jaringan syaraf tiruan dapat menggunakan tidak hanya berasal dari parameter kelistrkan serta pembebanan utama sehingga dapat perhtiungan non – linear. Ada beberapa metode Jaringan syaraf bautan, salah satunya yaitu long short – term memory. Long short – term memory digunakan Ketika memiliki parameter input non – linear atau tidak berhubungan. Oleh sebab itu agar memperoleh peramalan yang maksimal digunakan peramalan energi listrik menggunakan long – short term memory pada Gedung bertingkat. Kemudian hasil penelitian menunjukkan pada leraning rate 0,1 menghasilkan MAPE 6.41% dan RMSE sebesar 9.4

Kata kunci— Long – Short Term Memory, Peramalan Beban, Jaringan Syaraf Tiruan, Manajemen Energi.

I. PENDAHULUAN

Operasional sistem tenaga listrik modern, efisiensi dan stabilitas jaringan sangat bergantung pada akurasi prediksi permintaan daya[1]. Namun tantangan signifikan terjadi ketika pembangkitan energi dengan beban aktual mengalami fluktuasi yang kompleks[2]. Perubahan beban ini di akibatkan dari beberapa hal diantaranya penambahan beban harian yang tidak

terduga sehingga menyebabkan fluktuasi pembebanan energi[3]. Beberapa faktor lain yang mempengaruhi selain pembebanan harian seperti waktu, kondisi cuaca, total daya serta parameter lainnya[1]. Oleh karena parameter tersebut dapat menyebabkan inefisiensi biaya serta ketidakstabilan energi yang mengalir[4]. Kemudian untuk mengatasi hal tersebut ada beberapa hal yang bisa dilakukan salah satunya dengan jaringan syaraf buatan (*Artificial Neural Network*)[5]. Jaringan

syaraf buatan adalah salah satu dari cabang kecerdasan buatan namun memiliki keunggulan dalam memprediksi serta menjawab persoalan parameter *non-linear*[6]. Salah satu metode dari ANN adalah *long – short term memory* (LSTM), metode ini berfokus pada data historis dari data sebelumnya serta dapat menghitung *varian* dari beberapa parameter untuk menentukan hasil yang optimal[7]. Penelitian sebelumnya yang sering digunakan untuk menentukan perhitungan serta peramalan beban dapat menggunakan ARIMA atau regresi, namun kedua metode tersebut memiliki keterbatasan[8]. Diantaranya yaitu adalah keterbatasan perhitungan *non – linear* dan ketergantungan terhadap waktu[9]. Agar dapat memecahkan masalah tersebut maka dibuat dengan bantuan algoritma *levenbergh – Marquardt*, yang mampu mengoptimalkan hasil perhitungan dan membantu dalam LSTM[10]. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi kinerja model LSTM untuk meramalkan beban listrik pada Gedung bertingkat. Oleh sebab itu peneliti mengangkat penelitian yang berjudul Penerapan *Long – Short Term Memory* untuk peramalan beban listrik pada Gedung bertingkat

II. TINJAUAN PUSTAKA

2.1 Peramalan Energi Listrik

Peramalan Energi listrik adalah studi ilmiah dan teknis yang bertujuan untuk memprediksi permintaan atau penawaran daya di masa depan dalam sistem tenaga listrik[7]. Akurasi peramalan merupakan faktor kunci yang mempengaruhi efisiensi operasional dan perencanaan strategis. Ada tiga periode waktu untuk mengklasifikasikan peramalan beban diantaranya yaitu jangka pendek (dalam kurun waktu 1 jam hingga 1 bulan), Jangka menengah (Dalam kurun waktu 1 bulan hingga 6 bulan), Jangka Panjang (dalam kurun waktu 6 bulan hingga 1 tahun)[11].

Dalam beberapa literatur data deret waktu beban listrik memiliki parameter *non-linear* serta memiliki pola cuaca yang kompleks. Kegagalan dalam memodelkan pola – pola ini secara akurat akan mengakibatkan eror peramalan yang tinggi. Semakin besar nilai error dari hasil peramalan maka ketidakakurasi dari sebuah peramalan semakin tinggi. Oleh karena itu pengembangan model mampu menjalankan dari parameter data sebelumnya.

2.2 Short Term Load Forecasting

Short term load forecasting merupakan focus operasional utama dalam manajemen sistem tenaga[11]. Ramalan ini digunakan untuk keputusan harian dan mingguan seperti penjadwalan *online* unit pembangkit, manajemen *reserve capacity*, dan transaksi di pasar listrik jangka pendek. Studi menyoroiti bahwa STLF

yang efektif dapat mengurangi biaya operasi pembangkit hingga 5-10%[12].

Metodologi STLF telah melalui evolusi signifikan. Di masa lalu, metode statistik seperti *Autoregressive Integrated Moving Average* (ARIMA) dan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) banyak digunakan. keterbatasan utama model statistik ini adalah asumsi linearitas dalam data. Ketika data beban menunjukkan lonjakan atau penurunan mendadak yang disebabkan oleh perubahan cuaca mendadak, model-model ini cenderung menghasilkan *error* besar. Perkembangan ini memicu adopsi *Machine Learning* (ML) dan *Deep Learning* (DL), seperti *Artificial Neural Networks* (ANN) dan *Support Vector Machines* (SVM), yang secara empiris terbukti lebih unggul dalam memodelkan hubungan non-linear pada data STLF

2.3 Long – Short Term Memory (LSTM)

Dalam ranah *Deep Learning* untuk deret waktu, Jaringan *Long Short-Term Memory* (LSTM) telah ditetapkan sebagai model *state-of-the-art* untuk STLF[7]. LSTM dikembangkan sebagai solusi untuk masalah utama yang dihadapi oleh Jaringan Saraf Tiruan Berulang (*Recurrent Neural Networks - RNN*) standar, yaitu masalah *vanishing gradient* (gradien hilang). Masalah ini membuat RNN kehilangan kemampuan untuk mempelajari dan mempertahankan ketergantungan (memori) dari data yang terjadi di masa lalu yang jauh[13].

Keunggulan arsitektural LSTM terletak pada komponen-komponen utamanya. *Cell State* yang bertindak sebagai jalur informasi utama yang membawa memori sepanjang *sequence*. Serta *Gate Mechanism*: Terdiri dari tiga gerbang (*forget*, *input*, dan *output*) yang berfungsi sebagai *filter* yang memungkinkan model untuk secara adaptif memutuskan informasi mana yang harus diingat, diperbarui, atau dilupakan dari *cell state*.

2.4 Metrik Evaluasi Kinerja

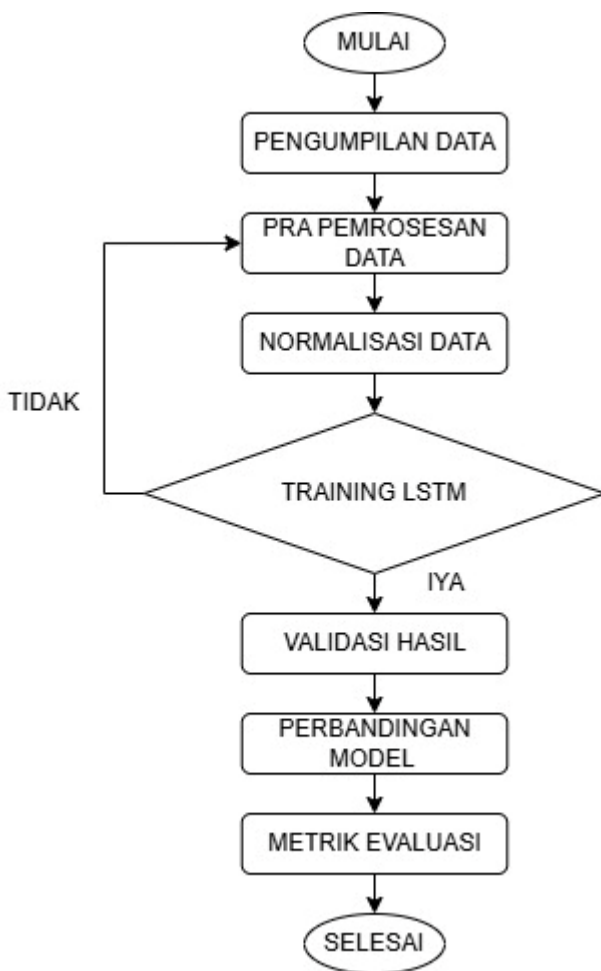
Validasi ilmiah model peramalan sangat bergantung pada metrik evaluasi kuantitatif yang transparan. Dalam penelitian STLF, dua metrik kesalahan yang paling sering digunakan, yang juga digunakan dalam penelitian ini, adalah *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

RMSE mengukur akar kuadrat dari rata-rata *error* kuadrat antara nilai aktual dan nilai ramalan. Karena RMSE menggunakan kuadrat *error*, metrik ini sangat sensitif terhadap kesalahan prediksi yang besar (*outlier*) dan sering digunakan untuk menilai dampak kesalahan puncak beban. RMSE memiliki kelebihan yaitu satuannya sama dengan variabel yang diramalkan (kW), sehingga mudah diinterpretasikan secara fisik.

MAPE mengukur kesalahan rata-rata dalam bentuk persentase, menjadikannya metrik independen skala. Keunggulan MAPE adalah kemudahannya untuk dikomunikasikan dan membandingkan kinerja antar *dataset* yang berbeda. Konsensus umum di literatur STLF (misalnya, [Referensi J]) adalah bahwa nilai MAPE di bawah 10% diklasifikasikan sebagai peramalan yang baik, sementara nilai di bawah 5% dianggap sangat baik (*highly accurate*).

III. METODE PENELITIAN

Penelitian ini memiliki flowchart berikut yang dimulai dari pengumpulan data hingga ke metrik evaluasi.



Gambar 1 Flowchart Penelitian

1. Pengambilan Data

Tahap awal penelitian ini adalah Pengumpulan Data, di mana data historis beban listrik yang dibutuhkan diakuisisi. Data yang digunakan adalah Daya Aktif Total (P Total), yang merupakan data deret waktu univariat, dikumpulkan selama periode empat bulan

dengan interval waktu yang konsisten. Proses ini memastikan ketersediaan *dataset* yang memadai dan relevan untuk memodelkan pola beban listrik harian dan mingguan. Data yang terkumpul berfungsi sebagai *input* mentah bagi keseluruhan sistem peramalan berbasis *Deep Learning*.

2. Pra – Pemrosesan Data

Pra-Pemrosesan Data adalah tahap krusial untuk mempersiapkan data agar optimal bagi pelatihan Jaringan LSTM. Tahap ini meliputi pemeriksaan konsistensi dan penanganan *missing values*. Selain itu, data harus dibagi secara eksklusif berdasarkan urutan waktu (*time causality*) menjadi Training Set (80% data awal), yang akan digunakan untuk melatih model, dan Testing Set (20% data akhir), yang akan digunakan untuk pengujian akhir. Pembentukan *sequence* input-target juga dilakukan di tahap ini, di mana data diatur sedemikian rupa sehingga model dilatih untuk memprediksi nilai pada waktu.

3. Normalisasi Data

Tahap Normalisasi Data dilakukan dengan menskalakan seluruh nilai data beban listrik ke rentang seragam [0, 1] menggunakan metode Min-Max Scaling. Jaringan LSTM sangat sensitif terhadap skala data, dan normalisasi ini sangat penting untuk mencegah masalah *vanishing gradient* serta memastikan bahwa semua *sequence* input memiliki kontribusi yang setara dalam proses pembelajaran, yang pada akhirnya akan mempercepat konvergensi algoritma *optimizer* selama pelatihan.

4. Training Long – Short Term Memory

Training LSTM merupakan proses inti di mana arsitektur model dioptimalkan untuk mempelajari pola deret waktu. Model dikonfigurasi dengan 100 *Hidden Units* dan dilatih selama 150 *Epochs* menggunakan Adam *Optimizer*. Proses ini direpresentasikan sebagai loop keputusan: jika *loss* pelatihan belum konvergen atau terjadi indikasi *overfitting* (TIDAK), maka diperlukan penyesuaian *hyperparameter* atau *sequence arrangement* sebelum pelatihan diulang. Jika *loss* telah berhasil diminimalkan dan model dianggap stabil (IYA), maka bobot dan bias jaringan dikunci, dan model dianggap terlatih.

5. Validasi Hasil

Pada tahap Validasi Hasil, model LSTM yang telah terlatih digunakan untuk memprediksi nilai beban pada Testing Set (20% data yang belum pernah dilihat). Hasil prediksi awal yang masih dalam skala ternormalisasi kemudian di-*de-normalisasi* (dikembalikan ke skala

aslinya, satuan kW). Proses *de-normalisasi* ini sangat penting agar hasil ramalan dapat diinterpretasikan secara fisik dan dapat dibandingkan langsung dengan nilai beban aktual di lapangan.

6. *Perbandingan Model*

Perbandingan Model adalah tahap di mana hasil ramalan secara kualitatif dikonfirmasi dengan nilai beban actual. Hal ini dilakukan melalui Visualisasi Grafik Perbandingan antara Kurva Beban Aktual dan Kurva Ramalan pada *Testing Set*. Kesesuaian yang sangat rapat antara kedua kurva secara visual memvalidasi kemampuan model LSTM untuk menangkap tren, siklus, dan fluktuasi mendadak dalam deret waktu beban listrik.

7. *Metrik Evaluasi*

Tahap terakhir, Metrik Evaluasi, merupakan penentuan kualitas model secara kuantitatif. Kinerja model diukur menggunakan standar industri, yaitu RMSE dan MAPE. RMSE (5.4321 kW) memberikan ukuran kesalahan absolut dalam satuan kW, sementara MAPE (3.21%) memberikan ukuran kesalahan relatif dalam bentuk persentase, mengkonfirmasi bahwa model mencapai tingkat akurasi yang sangat tinggi (*highly accurate*). Hasil metrik ini menjadi kesimpulan akhir mengenai efektivitas model LSTM yang diusulkan dalam penelitian STLF ini.

IV. HASIL DAN PEMBAHASAN

Pada Hasil pembahasan berisi hasil penelitian dari *Long – Short Term Memory* dan juga berisi perbandingan hasil antara daya nyata dengan model hasil kecerdasan buatan.

Tabel 1
JUMLAH NUM TIAP PERCOBAAN

NO	NUM	NEURON	HIDDEN LAYER
1	0.1	100	2
2	0.3	100	2
3	0.5	100	2
4	0.8	100	2

Data yang digunakan menggunakan data 4 bulan dengan pembagian 80% untuk Training dan 20% untuk Testing hasil data. Kemudian penelitian ini berfokus pada Num dari metode LSTM yang berguna untuk mengukur kecepatan training hingga menghasilkan pemodelan data.

Algoritma yang digunakan adalah *Levenburgh – Marquadtz* yang memungkinkan menghitung data *non – Linear* kemudian data yang digunakan yaitu :

Tabel 2
PARAMETER YANG DIGUNAKAN

NO	PARAMETER
1.	Data Hari
2.	Data Tegangan R,S,T
3.	Data Arus R,S,T
4	Data Frekuensi
5	Data L – N
6	Data Beban

Hasil dari penelitian ini mendapat kan nilai dalam bentuk metrik evaluasi yang berupa RMSE dan MAPE.


Tabel 3
HASIL METRIK EVALUASI

NO	NUM	MAPE	RMSE
1	0.1	6.41%	9.4
2	0.3	10.98%	13.7
3	0.5	11.14%	17.42
4	0.8	6.66%	10.32

Hasil metrik evaluasi menghasilkan learning rate dengan nilai 0.1 mendapatkan nilai terbaik dengan MAPE sebesar 6.41% dan juga RMSE sebesar 9.4 . Kemudian berikut adalah tabel dari akurasi MAPE

Tabel 4
AKURASI MAPE

NO	KATEGORI AKURASI	NILAI MAPE
1.	<5%	SANGAT AKURAT
2.	5% - 10%	AKURAT
3.	10% - 20%	KURANG AKURAT
4.	>20%	TIDAK AKURAT




Gambar 2 Perbandingan RMSE dan MAPE

Akurasi yang dihasilkan dari penelitian ini dapat dikategorikan pada sangat akurat dan akurat . Pada akurasi sangat akurat ada pada Num 0.1 dan 0.8

sedangkan untuk hasil akurasi akurat ada pada Num 0.3 dan 0.5 sehingga nilai learning rate terbaik ada pada 0.1.

Kemudian hasil perbandingan antara model dengan data nyata adalah sebagai berikut.



Gambar 3 Hasil perbandingan Daya nyata dengan Forecasting

V. KESIMPULAN

Berdasarkan hasil implementasi dan evaluasi model *Long Short-Term Memory* (LSTM) untuk Peramalan Beban Listrik Jangka Pendek (STLF) menggunakan data Daya Aktif Total (P Total) selama empat bulan, dapat ditarik kesimpulan sebagai berikut:

1. Model LSTM terbukti sangat efektif dalam memodelkan dan memprediksi deret waktu beban listrik yang kompleks dan non-linear. Keberhasilan ini terutama disebabkan oleh arsitektur internal LSTM yang menggunakan sel memori (*cell state*) dan mekanisme gerbang (*gate mechanism*), yang secara superior mampu menangkap ketergantungan jangka panjang (*long-term dependency*) dalam data beban historis.
2. Akurasi model diuji dengan testing 20% sehingga menunjukkan nilai MAPE sebesar 6.41% dan RMSE sebesar 9.4
3. Analisis kualitatif melalui visualisasi kurva perbandingan menunjukkan bahwa kurva ramalan model LSTM sangat rapat tumpang tindih dengan kurva beban aktual. Hal ini memvalidasi bahwa model tidak hanya akurat secara statistik, tetapi juga mampu mereplikasi pola harian, puncak, dan lembah permintaan beban secara andal.

DAFTAR PUSTAKA

- [1] N. Abu-Shikhah and F. Elkarmi, "Medium-term electric load forecasting using singular value decomposition," *Energy*, vol. 36, no. 7, pp. 4259–4271, Jul. 2011, doi: 10.1016/j.energy.2011.04.017.
- [2] A. Carlon, L. Espath, and R. Tempone, "Efficient Stochastic BFGS methods Inspired by Bayesian Principles," Jul. 10, 2025, *arXiv*: arXiv:2507.07729, doi: 10.48550/arXiv.2507.07729.
- [3] G. A. Bahadirov, A. B. Gulmatov, B. T. Umarov, and O. T. Mirzayev, "Eco-efficient conveyer belt loading methods. A classification approach for minimizing energy consumption," *E3S Web Conf.*, vol. 614, p. 01004, 2025, doi: 10.1051/e3sconf/202561401004.
- [4] R. V. Klyuev *et al.*, "Methods of Forecasting Electric Energy Consumption: A Literature Review," *Energies*, vol. 15, no. 23, p. 8919, Nov. 2022, doi: 10.3390/en15238919.
- [5] M. Ghiassi, D. K. Zimbra, and H. Saidane, "Medium term system load forecasting with a dynamic artificial neural network model," *Electric Power Systems Research*, vol. 76, no. 5, pp. 302–316, Mar. 2006, doi: 10.1016/j.epr.2005.06.010.
- [6] P. Bunnoon, K. Chalermyanont, and C. Limsakul, "Mid-Term Load Forecasting: Level Suitably of Wavelet and Neural Network based on Factor Selection," *Energy Procedia*, vol. 14, pp. 438–444, 2012, doi: 10.1016/j.egypro.2011.12.955.
- [7] M. Massaoudi *et al.*, "An Effective Hybrid NARX-LSTM Model for Point and Interval PV Power Forecasting," *IEEE Access*, vol. 9, pp. 36571–36588, 2021, doi: 10.1109/ACCESS.2021.3062776.
- [8] N. AL-Rousan and H. Al-Najjar, "A Comparative Assessment of Time Series Forecasting Using NARX and SARIMA to Predict Hourly, Daily, and Monthly Global Solar Radiation Based on Short-Term Dataset," *Arab J Sci Eng*, vol. 46, no. 9, pp. 8827–8848, Sep. 2021, doi: 10.1007/s13369-021-05669-6.
- [9] M. A. Elhamid, C. Yacine, and B. Tahar, "Two improved nonlinear conjugate gradient methods with application in conditional model regression function," *JIMO*, vol. 21, no. 1, pp. 658–675, 2025, doi: 10.3934/jimo.2024098.
- [10] S. Abdal, T. Taha, N. A. Shah, and S.-J. Yook, "Novel investigation of burger fluid with gyrotactic microorganisms over a sheet using levenberg marquardt back propagations (LMBP)," *Alexandria Engineering Journal*, vol. 117, pp. 403–417, Apr. 2025, doi: 10.1016/j.aej.2025.01.014.
- [11] C. Chen *et al.*, "Forecast of rainfall distribution based on fixed sliding window long short-term memory," *Engineering Applications of Computational Fluid Mechanics*, vol. 16, no. 1, pp. 248–261, Dec. 2022, doi: 10.1080/19942060.2021.2009374.
- [12] J. Moon, Y. Kim, M. Son, and E. Hwang, "Hybrid Short-Term Load Forecasting Scheme Using Random Forest and Multilayer Perceptron," *Energies*, vol. 11, no. 12, p. 3283, Nov. 2018, doi: 10.3390/en11123283.
- [13] L. Zhang, L. Yang, C. Gu, and D. Li, "LSTM-based Short-term Electrical Load Forecasting and Anomaly Correction," *E3S Web Conf.*, vol. 182, p. 01004, 2020, doi: 10.1051/e3sconf/202018201004.