

## Pemodelan Peramalan Beban Jangka Pendek untuk Subsistem Krian-Gresik Menggunakan *Deep Learning LSTM-NN*

**Bahrul Anas Septian**

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya  
e-mail: bahrul.19001@mhs.unesa.ac.id

**Unit Three Kartini**

S1 Teknik Elektro, Fakultas Teknik, Universitas Negeri Surabaya  
e-mail: unitthree@unesa.ac.id

### Abstrak

Sistem Perencanaan yang baik dibutuhkan untuk alasan efisiensi daya bangkitan, salah satunya adalah kegiatan *forecasting* atau peramalan terhadap konsumsi beban. Penelitian ini yakni membuat sebuah pemodelan peramalan menggunakan metode *Long Short Term Memory (LSTM)* yaitu salah satu arsitektur pada *Deep Learning* untuk melakukan peramalan jangka pendek selama 1 hari ke depan pada subsistem Krian-Gresik. Dilakukan beberapa eksperimen dengan mengubah beberapa parameter diantaranya lags, epoch dan batch. Kombinasi parameter yang menghasilkan prediksi yang paling baik adalah saat jumlah lags = 2, epoch = 250, dan batch = 256, dengan nilai akurasi MAPE = 1.75% dan MSE = 0.0155 serta grafik hasil prediksi yang mendekati pola dari data aktual.

**Kata Kunci:** LSTM, Deep Learning, Forecasting, Neural Network, Load.

### Abstract

A good planning system is needed for the sake of power generation efficiency, and one of its components is forecasting or predicting load consumption. This study focuses on creating a forecasting model using the *Long Short Term Memory (LSTM)* method, which is one of the architectures in Deep Learning, to forecast short-term load consumption for the next day in the Krian-Gresik subsystem. Several experiment were conducted by modifying various parameters. Including lags, epoch and batch sizes. The combination of parameters that resulted in good predictions is when the number of lags = 2, epoch = 250 and batch = 256, with an accuracy of MAPE = 1.75% and MSE = 0.0115, as well as prediction graphs that closely matched the pattern of actual data.

**Keywords:** LSTM, Deep Learning, Forecasting, Neural Network, Load.

### PENDAHULUAN

Listrik sudah menjadi kebutuhan primer bagi masyarakat di zaman modern ini. PT. PLN sebagai pihak penyedia energi listrik harus memastikan bahwasanya distribusi energi listrik ke masyarakat berjalan maksimal dan sesuai dengan kebutuhan. PT. PLN perlu secara konsisten memastikan bahwa setiap komponen dalam sistem tenaga listrik tetap dapat diandalkan. Sistem tersebut terdiri dari beberapa elemen, termasuk pembangkit listrik, transmisi, distribusi dan beban yang saling terhubung dan bekerja sama untuk memenuhi kebutuhan energi listrik bagi pelanggan (Slamet, 2016). Sistem perencanaan yang baik juga diperlukan untuk memastikan efisiensi daya bangkitan. Sub-sistem Krian-Gresik 150 kv adalah salah satu komponen sistem tenaga listrik bagian transmisi, yang melayani transmisi tenaga listrik pada area Krian-Gresik (Dita, 2017). Berdasarkan PT. PLN UP2B Jatim, subsistem Krian-Gresik memiliki nilai pembebanan tertinggi di antara subsistem lain yang ada di Jawa Timur (UP2B Jatim, 2022). Oleh karena itu, maka diperlukan suatu sistem perencanaan atau peramalan beban

yang akurat pada subsistem Krian-Gresik guna menjaga efektifitas dan efisiensi pembangkitan di masa yang akan datang.

Peramalan (*forecasting*) adalah suatu proses memperkirakan kejadian/hal di masa yang akan datang dengan bermacam teknik perhitungan. *Artificial Intelligence (AI)* merupakan teknologi era baru yang mempunyai kemampuan dalam melakukan *forecasting* dengan metode *Deep Learning* (Scott, 2018). Dalam sistem tenaga listrik, peramalan biasanya terkait daya bangkitan dan konsumsi energinya (Spyros dkk, 2020) Terdapat beberapa arsitektur di dalam *deep learning* salah satunya adalah *Long Short Term Memory (LSTM)*, merupakan suatu algoritma atau pemodelan jenis *Recurrent Neural Network (RNN)* yang memungkinkan jaringan berulang secara mendalam serta mampu memahami pola yang disimpan dalam jangka waktu yang lama (Sanskriti, 2018 ; Hocreiter dan Schimdhuber, 1977). Dengan kemampuan tersebut maka LSTM akan digunakan dalam penelitian ini.

Penggunaan metode LSTM sebagai model prediksi sudah sering dilakukan dalam berbagai

bidang, salah satunya dilakukan oleh Roby pada tahun 2021 untuk peramalan harga saham pada bursa efek Indonesia menggunakan LSTM, dan menghasilkan nilai akurasi yang cukup baik dalam setiap peningkatan epoch (Roby, 2021). Pada tahun 2020 juga digunakan pemodelan LSTM untuk melakukan peramalan kasus positif Covid 19 di Indonesia (Prisca, 2020). Begitu pula dalam bidang kelistrikan, penelitian *Short-term Load Forecasting Using an LSTM Neural Network* mendapatkan output terbaik menggunakan LSTM jika dibandingkan dengan metode-metode lain seperti ARIMA, GRNN dan ELM (Mohammad, 2020 ; Shahzad, 2019). Penelitian yang dilakukan bertujuan untuk membandingkan metode LSTM dengan beberapa metode lain antara lain, penelitian *a deep learning approach for load demand forecasting of power system*, penelitian metode *multilayer perceptron (MLP)* dan *l longshort term memory (LSTM)* dalam peramalan harga beras , Penelitian analisis algoritma CNN dan LSTM untuk memprediksi tinggi muka air di DKI Jakarta Indonesia, penelitian *a comparative study of LSTM and ARIMA for energy load prediction with enhanced data preprocessing* (Illiana, 2018 ; Steven, 2020 ; Ayu, 2022 ; Innocent, 2020)

Penelitian ini bertujuan untuk membuat pemodelan peramalan menggunakan LSTM untuk melakukan peramalan jangka pendek untuk konsumsi beban listrik pada subsistem Krian-Gresik selama 1 hari ke depan dengan interval waktu peramalan per-30 menit. Proses yang terjadi pada penelitian ini adalah untuk mencari kombinasi parameter-parameter terbaik yang memiliki nilai akurasi terbaik dan grafik hasil peramalan yang mampu mengikuti pola dari data aktual. Selain dari mengamati hasil grafik prediksi dari model, indeks keandalan juga diukur menggunakan beberapa metrik yaitu MAPE (*Mean Absolute Percentage Error*) dan MSE (*Mean Squared Error*). Hasil dari penelitian ini diharapkan memberikan manfaat bagi pembaca khususnya bagi pihak penyedia energi listrik dalam upaya untuk menyediakan listrik yang andal, efektif dan efisien. Serta mampu menjadi sumber wawasan baru bagi peneliti lain dalam pengembangan metode *Deep Learning LSTM*.

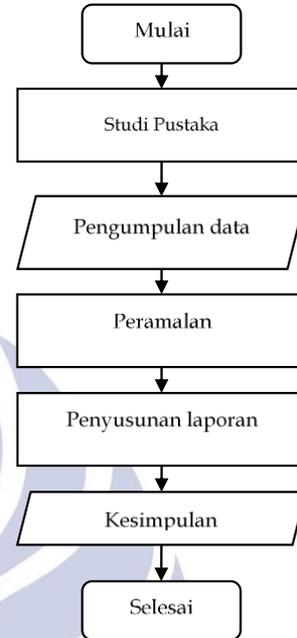
## METODE

### Rancangan Penelitian

Penelitian ini menggunakan pendekatan eksperimen. Pengetahuan dan kesimpulan didapat dari data dari hasil eksperimen. Terdiri dari beberapa tahapan yaitu dimulai dengan studi pustaka, pengumpulan data, proses peramalan, penyusunan laporan, dan kesimpulan seperti yang ditunjukkan pada Gambar 1.

Penelitian ini dilakukan dengan mengumpulkan data historis konsumsi beban listrik subsistem Krian-Gresik yang dikumpulkan oleh PT. PLN UP2B Jawa Timur selama rentang waktu 2 bulan dengan interval waktu pencatatan

per 30 menit dalam sehari yakni mulai 1 Mei 2022 hingga 30 Juni 2022. Data tersebut digunakan sebagai data input atau juga sebagai variabel input untuk melakukan prediksi jangka pendek konsumsi beban listrik pada subsistem Krian-Gresik selama 1 hari ke depan yaitu pada tanggal 1 Juli 2022.



Gambar 1 Rancangan Penelitian

### Preprocessing Data

Sebelum dilakukan pemodelan LSTM, data yang digunakan perlu diproses terlebih dahulu, dengan langkah-langkah seperti berikut :

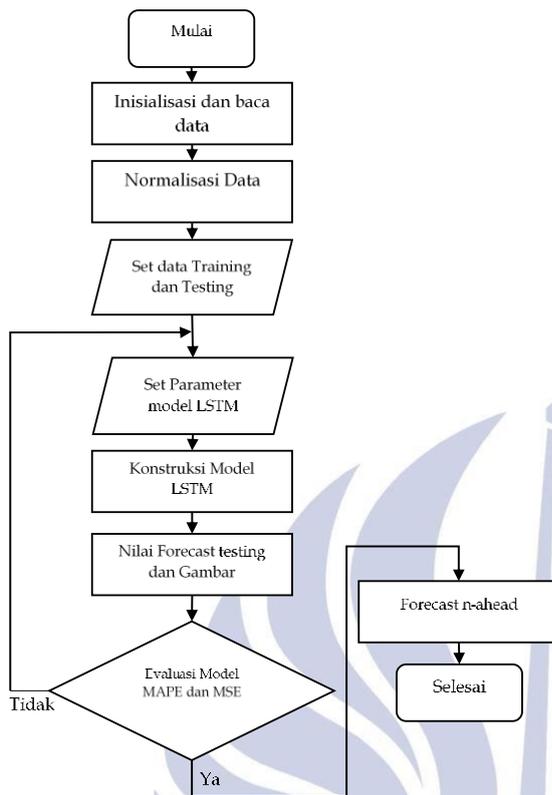
1. Konversi data menjadi format waktu (*time series*) untuk menjelaskan informasi urutan waktu pada data.
2. Normalisasi data untuk menghilangkan perbedaan skala dengan tujuan agar model lebih mengolah data.
3. Membagi data menjadi dua bagian, yakni data *training* dan data *testing*. Data *training* digunakan untuk melatih model dalam memahami pola pada data, sedangkan data *testing* digunakan untuk menguji dan mengevaluasi model.

### Pemodelan LSTM

Penelitian ini akan menguji kemampuan model LSTM dalam melakukan prediksi. Beberapa tahapan yang akan dilakukan dapat dilihat pada Gambar 2.

Pertama dilakukan preprocessing data, kemudian model akan melakukan proses pelatihan dari data *training* dan kemudian menguji hasil *training* menggunakan data *testing*. Hasil dari proses tersebut berupa nilai akurasi peramalan dan grafik. Jika model menunjukkan performa yang baik dalam melakukan peramalan, maka parameter yang sudah terbentuk tersebut dapat diuji validasi dalam

melakukan *forecast n-ahead* atau peramalan beberapa langkah ke depan.



**Gambar 2** Pemodelan Peramalan LSTM

Semua proses peramalan dilakukan dengan bahasa pemrograman python. Mengubah data menjadi objek waktu dengan modul *datetime*. Normalisasi dilakukan dengan *MinMaxScaler* dari *library Scikit-Learn*. Konstruksi model menggunakan modul LSTM dari *library Keras*. Set data *training* dan *testing* mengacu pada proporsi pembagian data yang digunakan sebagai data pembelajaran dan data uji dari kombinasi yang terbentuk. Metrik evaluasi MAPE digunakan untuk menghitung rata-rata dari seluruh nilai prediksi dan nilai aktual dalam bentuk presentase sementara MSE digunakan untuk menghitung nilai rata-rata dari selisih kuadrat antara nilai prediksi dan nilai aktual.

**HASIL DAN PEMBAHASAN**

**Simulasi**

Simulasi berupa percobaan-percobaan dengan memvariasikan parameter-parameter pada model. Parameter tersebut diantaranya : (1) *Lags*, yaitu jumlah *timestep* atau langkah sebelumnya yang dijadikan input, (2) *LSTM layer Depth*, yaitu jumlah layer pada model, (3) *Epoch*, yaitu jumlah pelatihan dari seluruh dataset, (4) *Batch*, yaitu jumlah pembagian dari dataset yang diproses bersamaan,

(5) Presentase penggunaan data *training* dan data *testing*. Pada penelitian ini, hanya akan memvariasikan jumlah lags, epoch dan batch.

Simulasi akan dibagi menjadi 3 bagian, yaitu simulasi *training*, simulasi *testing* dan simulasi *n-ahead*, di mana model akan diuji untuk melakukan peramalan 1 hari ke depan dari data terakhir atau data baru yang belum pernah terlihat, yang dalam penelitian ini adalah data konsumsi beban pada tanggal 1 Juli 2022, dengan parameter terbaik yang sudah terbentuk. Evaluasi model dilakukan dengan mengukur nilai akurasi yang diukur dengan metrik evaluasi MAPE yang mangacu pada deviasi nilai prediksi dan nilai aktual dalam bentuk presentase dan MSE dalam bentuk nilai kuadrat. Selain itu, evaluasi model juga dilakukan dengan mengamati gambar grafik pola perbandingan hasil prediksi dan pola dari data aktual.

**Hasil Simulasi**

**Simulasi 1 : Data Training**

Simulasi data *training* dilakukan untuk melihat performa model dalam melakukan pembelajaran. Proporsi pada data *training* yakni 85% dari total data. Dilakukan variasi peningkatan pada jumlah epoch, lags dan batch untuk melihat pengaruh dari jumlah parameter terhadap hasil prediksi. Mendapatkan hasil yang ditunjukkan pada tabel 1. Tabel 1 menunjukkan nilai akurasi pada tiap peningkatan epoch, lags dan batch.

**Tabel 1** Nilai akurasi kombinasi parameter pada tiap peningkatan epoch, lags dan batch

No	Epoch	lags	batch	MAPE (%)	MSE
1	250	6	256	6.95	0.0123
2	500	6	256	7.05	0.0126
3	1000	6	256	7.10	0.0128
4	3000	6	256	7.21	0.0132
5	5000	6	256	7.36	0.0134
6	8000	6	256	7.20	0.0132
7	250	2	256	2.44	0.0019
8	250	12	256	12.34	0.31
9	250	24	256	16.87	0.057
10	250	48	256	7.37	0.016
11	250	336	256	11.80	0.036
12	250	1440	256	20.78	0.064
13	250	2	16	2.76	0.0021
14	250	2	32	2.56	0.0020
15	250	2	64	2.55	0.0020
16	250	2	128	2.47	0.0020
17	250	2	256	2.35	0.0018
18	250	2	512	1.37	0.0005

Dilihat pada tabel 1 bahwasanya penambahan jumlah epoch cenderung tidak membuat hasil prediksi semakin baik, dan hasil nilai akurasi pada tiap peningkatannya tidak terlalu signifikan. Penambahan jumlah lags juga tidak membuat nilai akurasi semakin baik, namun perbedaan nilai akurasi pada tiap peningkatannya cukup signifikan. Berbeda dari 2 parameter sebelumnya, penambahan jumlah batch mampu membuat nilai akurasi semakin baik.

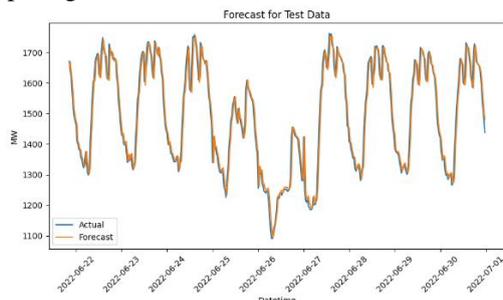
**Simulasi 2 : Data Testing**

Simulasi data *testing* dilakukan untuk menguji kombinasi parameter terbaik yang sudah terbentuk ketika melakukan pembelajaran. Pengujian dilakukan terhadap 15% sisa data dari pembagian data *training*. Simulasi ini bertujuan untuk melihat dan mengevaluasi kinerja model dengan membandingkan nilai hasil prediksi dan nilai aktual. Pengujian dilakukan terhadap 3 kombinasi parameter terbaik pada tiap peningkatan jumlah epoch, lags dan batch pada simulasi 1. Hasil pengujian ditunjukkan pada tabel 2.

**Tabel 2** Nilai akurasi 3 parameter terbaik pada tiap peningkatan epoch, lags dan batch pada data testing

No	Epoch	Lags	Batch	MAPE (%)	MSE
1.	250	6	256	2.40	0.159
2.	250	2	256	1.78	0.155
3.	250	2	512	1.75	0.155

Simulasi ini juga sekaligus bertujuan untuk melihat apakah pefoma yang ditunjukkan model pada simulasi *training* menghasilkan hasil yang sama baiknya ketika melakukan prediksi pada data testing. Dapat dilihat pada tabel 2, bahwasanya kombinasi parameter terbaik pada saat proses *training* juga menghasilkan nilai akurasi yang paling baik pada saat prediksi pada data testing. Grafik hasil prediksi dari kombinasi parameter epoch = 250, lags = 2 dan batch = 256 dapat dilihat pada gambar 3.

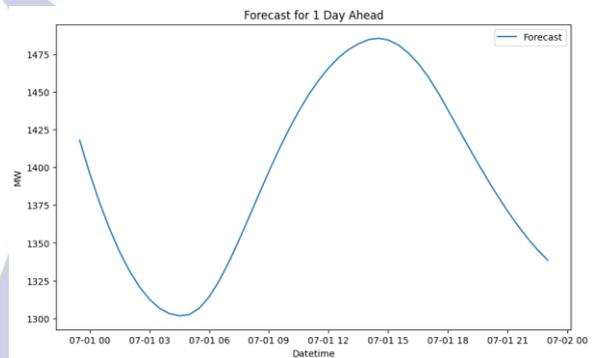


**Gambar 3** Hasil prediksi data testing saat epoch = 250, lags = 2 dan batch 256

Dari gambar 3 dapat dilihat bahwasanya model mampu menghasilkan prediksi yang sangat baik pada data yang belum pernah dilihat sebelumnya. Pola prediksi yang dihasilkan sangat mengikuti pola dari 15% data aktual.

**Simulasi 3 : Uji Validasi (Peramalan 1 hari ke depan)**

Pada simulasi ini dilakukan pengujian terhadap kombinasi parameter yang terbaik dalam melakukan uji validasi dalam melakukan data *training* dan *testing* dalam melakukan preamalan 1 hari ke depan. Gambar 4 menunjukkan hasil prediksi *real time* 1 hari ke depan dari kombinasi parameter epoch 250, lags = 2 dan batch = 256.



**Gambar 4** Hasil prediksi 1 hari ke depan

Dapat dilihat pada gambar 4 bahwasanya pola hasil prediksi menghasilkan fluktuasi di mana pada jam-jam tertentu nilai beban turun, dan pada jam-jam tertentu nilai beban naik.

**Hasil Analisis**

Kombinasi parameter dengan epoch = 250, lags = 2 dan batch = 256 mampu menghasilkan performa yang baik pada model. Kinerja model dengan parameter tersebut sangat baik dimulai ketika saat data *training* proses pembelajaran, dilanjutkan ketika data *testing* dan kemudian pada uji coba terhadap data *real time* n-ahead.

Penambahan jumlah epoch cenderung tidak membuat hasil prediksi semakin baik, dan hasil nilai akurasi pada tiap penambahannya perbedaannya tidak terlalu signifikan. Hal ini kemungkinan terjadi karena model sudah mencapai titik konvergensi pada nilai epoch yang rendah. Titik konvergensi yakni kondisi dimana model memperoleh kestabilan atau konsistensi dalam pembelajarannya.

Jumlah lags yang memiliki nilai akurasi terbaik adalah saat berjumlah 2 lags. Hal ini kemungkinan terjadi karena model dapat menangkap tren atau pola pada interval yang lebih pendek, yakni perjam. Penambahan jumlah lags kemungkinan tidak memberikan tambahan informasi yang signifikan

Penambahan pada jumlah batch membuat nilai akurasi semakin baik. hal ini kemungkinan terjadi karena jumlah batch sangat mempengaruhi kecepatan pembelajaran yang dilakukan oleh model serta mampu membuat model lebih cepat ke titik konvergensi.

## PENUTUP

### Simpulan

Berdasarkan hasil eksperimen dan analisis terkait peramalan beban listrik jangka pendek menggunakan pemodelan LSTM, dapat ditarik kesimpulan bahwasanya parameter yang digunakan yakni lags, epoch dan batch sangat berpengaruh terhadap hasil prediksi. Kombinasi parameter terbaik pada penelitian ini dengan karakteristik data inputan yang digunakan, dengan nilai akurasi paling minim dan hasil grafik peramalan yang mengikuti pola atau tren dari data aktual adalah saat epoch = 250, lags = 2 dan batch = 256 dengan MAPE = 1.75% dan MSE = 0.0155. Model menghasilkan prediksi yang baik saat menangkap pola dengan interval yang lebih pendek.

### Saran

Dalam upaya mendapatkan hasil yang lebih baik dari pemodelan LSTM untuk melakukan peramalan jangka pendek konsumsi beban listrik pada penelitian-penelitian selanjutnya, peneliti menyarankan untuk menambah dataset inputan yang digunakan. Semakin banyak data inputan maka membuat model akan lebih baik dalam melakukan pembelajaran. Sehingga akan menghasilkan prediksi yang lebih akurat baik pada nilai akurasi maupun pola grafik peramalan yang mengikuti data aktual.

## DAFTAR PUSTAKA

- Hochreiter. S., dan Schmidhuber. J., 1997. *Long short-term memory*. Neural computation, 9(8), 1735-1780.
- Hossain. M. S. dan Mahmood. H. 2020. *Short-term load forecasting using an LSTM neural network*. In 2020 IEEE Power and Energy Conference at Illinois (PECI) (pp. 1-6). IEEE.
- Julian. R. dan Pribadi. M. R. 2021. *Peramalan harga saham pertambangan pada bursa efek indonesia (BEI) menggunakan long short term memory (LSTM)*. JATISI (Jurnal Teknik Informatika dan Sistem Informasi), 8(3), 1570-1580.
- Kevinamarta. D. dan Wrahatnolo. T. 2017. *Evaluasi keandalan sistem tenaga listrik subsistem krian-gresik 150 kV dengan metode analisis kontingensi (N-1)*. Jurnal Teknik Elektro, 6(1).
- Kollia. I. dan Kollias. S. 2018. *A deep learning approach for load demand forecasting of power systems*. In 2018 IEEE Symposium Series on Computational Intelligence (SSCI) (pp. 912-919). IEEE.
- Mpawenimana. I., Pegatoquet. A., Roy. V., Rodriguez. L. dan Belleudy, C. 2020. *A comparative study of LSTM and ARIMA for energy load prediction with enhanced data preprocessing*. In 2020 IEEE Sensors Applications Symposium (SAS) (pp. 1-6). IEEE.
- Muzaffar. S. dan Afshari. A. 2019. *Short-term load forecasts using LSTM networks*. Energy Procedia, 158, 2922-2927.
- Pakan. P.D. 2020. *Peramalan Kasus Positif Covid 19 Di Indonesia Menggunakan Lstm*. Jurnal Ilmiah Flash, 6(1), 12-15.
- Patel. S. dan Patel. A. 2018. *Deep leaning architectures and its applications: a survey*. International journal of computer sciences and engineering, 6(6), 1177-1183.
- PT. PLN UP2B Jawa Timur. 2022. *Sistem Kelistrikan Jawa Timur*.
- Scott. 2018. *Deep Learning for Dummies*. John Wiley & Sons, Inc.
- Sen. S., Sugiarto. D. dan Rochman. A. 2020. *Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM) dalam Peramalan Harga Beras*. Ultimatics: Jurnal Teknik Informatika, 12(1), 35-41.
- Spyros Makridakis, dkk. 2020. *Forecasting in Social Setting : The State of Art*. International Journal of Forecasting.
- Suripto. Slamet. 2016. *Sistem Tenaga Listrik*. teknik elektro-umy
- Wulandari. A. 2022. *Analisis Kinerja Algoritma Cnn Dan Lstm Untuk Memprediksi Tinggi Muka Air Di Dki Jakarta, Indonesia*. Doctoral dissertation, Universitas Mercu Buana Jakarta.



**UNESA**

**Universitas Negeri Surabaya**