

PERAMALAN BEBAN PADA RENCANA OPERASI HARIAN DENGAN MENGGUNAKAN LSTM STUDI KASUS : SUB SISTEM SULAWESI SELATAN

Muhammad Abdul Wakhid¹⁾, Agus Budi Raharjo²⁾, Rio Indralaksono³⁾ dan Diana Purwitasari⁴⁾

^{1, 2,3,4)}Magister Manajemen Teknologi, Institut Teknologi Sepuluh November

Jl. Cokroaminoto No.12A, DR. Soetomo, Kec. Tegalsari, Kota SBY, Jawa Timur

e-mail: login.wahid@gmail.com¹⁾, agus.budi@its.ac.id²⁾, rio@indralaksono.net³⁾ diana@if.its.ac.id⁴⁾

ABSTRAK

Beban listrik yang dibutuhkan pada suatu sub sistem ketenagalistrikan selalu berubah setiap harinya. Operator tenaga listrik harus mampu membangkitkan dan menyalurkan listrik sesuai kebutuhan konsumen. Pada sub sistem Sulawesi, pembangkit listrik yang digunakan masih didominasi oleh pembangkit dengan bahan bakar fosil sehingga pada operasionalnya, kebutuhan bahan bakar perlu mendapat perhatian serius. Perencanaan konsumsi listrik harian yang baik sangat diperlukan sehingga biaya bahan bakar menjadi optimal. Pada kondisi sekarang peramalan beban untuk Rencana Operasi Beban Harian (ROH) masih dilakukan berdasarkan Expert Judgment yang berbeda beda untuk setiap forecaster. Dengan batas toleransi kesalahan yang cukup besar yaitu 4%. Diperlukan sebuah instrumen peramalan beban yang mampu menghasilkan data dengan toleransi eror yang lebih baik. Metode peramalan seperti ARIMA, SARIMA dan ARIMAX sudah digunakan selama bertahun tahun. Dalam beberapa tahun terakhir, beberapa tehnik kecerdasan buatan seperti Neural Network dan machine learning mulai dikembangkan untuk analisa time series. Dan akhir-akhir ini Artificial Neural Network (ANN) dan Recurrent Neural Network (RNN) menunjukkan hasil peramalan yang lebih akurat dibandingkan metode peramalan tradisional. Long Short Term Memori (LSTM) adalah salah satu model dari RNN yang menggunakan data lampau (Long Term) untuk meramalkan data sekarang (Short Term). Data realisasi beban harian sistem Sulawesi Selatan digunakan sebagai data training setelah sebelumnya dilakukan normalisasi dengan menggunakan min-max. Model LSTM dibuat dengan menggunakan data input yang berbeda-beda. Performa dari masing-masing model tersebut kemudian dievaluasi dengan membandingkan nilai RMSE dan MAPE. Dari beberapa model masukan data tersebut, model peramalan dengan menggunakan input data harian memiliki performa yang lebih baik dibanding kan skenario yang lain. Nilai MAPE dan RMSE yang diperoleh adalah sebesar 2,384% dan 33,95MW.

Kata Kunci: Peramalan Beban Jangka Pendek, LSTM, Pembelajaran Mesin.

LOAD FORECASTING FOR DAILY LOAD OPERATIONAL PLAN USING LSTM CASE STUDY : SOUTH SULAWESI SUB SYSTEM

Muhammad Abdul Wakhid¹⁾, Agus Budi Raharjo²⁾, Rio Indralaksono³⁾ and Diana Purwitasari⁴⁾

^{1, 2,3,4)}Magister Manajemen Teknologi, Institut Teknologi Sepuluh November

Jl. Cokroaminoto No.12A, DR. Soetomo, Kec. Tegalsari, Kota SBY, Jawa Timur

e-mail: login.wahid@gmail.com¹⁾, agus.budi@its.ac.id²⁾, rio@indralaksono.net³⁾ diana@if.its.ac.id⁴⁾

ABSTRACT

The electrical load required in an electricity sub-system changes every day. Electric power operators must be able to generate and distribute electricity according to consumer needs. In the Sulawesi sub-system, the power plants used are still dominated by fossil fuel generators, so that in their operations, fuel requirements need to be given serious attention. Planning a good daily electricity consumption is needed so that the fuel cost becomes optimal. In the current condition, the load forecasting for the Daily Load Operation Plan (ROH) is still based on Expert Judgment, which is different for each forecaster. With a fairly large error tolerance limit of 4%. We need a load forecasting instrument capable of better error tolerance. Forecasting methods such as ARIMA, SARIMA and ARIMAX have been used for many years. In recent years, several artificial intelligence techniques such as Neural Network and machine learning have been developed for time series analysis. And recently, more accurate forecasting results are shown by Artificial Neural Network (ANN) and Recurrent Neural Network (RNN) compared to traditional forecasting methods. Long Short Term Memory (LSTM) is a model of RNN that uses past data (Long Term) to predict current data (Short Term). Electric load in Sulawesi subsystem used as data training after normalized using min-max normalization. The LSTM model is made with different data input. Forecasting performance of each model is then evaluated based on the RMSE and MAPE values. Of the several data input models, forecasting models with daily data input show better performance than other scenarios. The MAPE and RMSE values obtained were 2.384% and 33.95, respectively.

Keywords: Short Term Load Forecasting, LSTM, Machine Learning.

I. PENDAHULUAN

PERENCANAAN Operasi Sistem adalah perencanaan pengoperasian sistem tenaga listrik yang meliputi perencanaan pembangkitan dan penyaluran untuk mencapai tujuan dari operasi sistem tenaga listrik yaitu ekonomis, andal, dan berkualitas. Perencanaan operasi sistem diperlukan agar energi listrik diproduksi menyesuaikan kebutuhan konsumen, untuk menjaga ketersediaan energi dan keperluan pemeliharaan instalasi (Transmisi dan Pembangkit). Sesuai *Grid Code* terbaru (Permen ESDM No. 20 tahun 2020), perencanaan operasi terbagi menjadi 5 periode, yaitu Rencana Operasi Tahunan (ROT), Rencana Operasi Bulanan (ROB), Rencana Operasi Mingguan (ROM), Rencana Operasi Harian (ROH), dan waktu nyata untuk kebutuhan *redispatch* (peramalan ulang dalam jangka pendek pada periode hari yang sama). Isi dari perencanaan operasi sistem tersebut meliputi prakiraan beban (rencana energi), perencanaan pembangkit tenaga air, penjadwalan pembangkit, penjadwalan penyaluran dan penyusunan rencana daya. Prakiraan beban konsumen digunakan sebagai dasar dalam merencanakan pembangkitan dan penyaluran. Konsumsi energi listrik sendiri dipengaruhi oleh banyak faktor seperti cuaca, hari kerja, akhir pekan maupun hari libur [1]. Sehingga diperlukan model peramalan beban yang mampu menghasilkan tingkat akurasi yang baik. Akurasi prakiraan beban berpengaruh terhadap keekonomian pengoperasian sistem tenaga listrik [2]. Secara garis besar, alur perencanaan operasi sistem ketenagalistrikan dapat dilihat pada Gambar 1.

Sistem kelistrikan di Sulawesi Selatan memiliki bauran energi yang beragam. Pembangkit berbahan bakar fosil dengan kapasitas besar ditambah pembangkit listrik tenaga air dan pembangkit tenaga angin yang bersifat *intermittent*, memerlukan perencanaan pembangkit yang matang. Konsumsi listrik dari konsumen besar seperti pabrik, perhotelan dan industri pengolahan nikel sangat mempengaruhi kebutuhan listrik di Sistem Sulawesi Selatan. Untuk mengatur kebutuhan energi listrik harian di Sistem Sulawesi Selatan, *dispatcher* membuat perkiraan kebutuhan energi yang disusun dalam Rencana Operasi Harian (ROH). ROH adalah perkiraan beban energi listrik yang dibutuhkan pada hari tersebut. ROH harus disusun dengan tingkat kesalahan seminimal mungkin. Sehingga perencanaan kebutuhan energi listrik yang dibangkitkan dan disalurkan harus mampu memperkirakan kebutuhan beban [3]. Di sistem Sulawesi Selatan, peramalan beban untuk menyusun Rencana Operasi Harian (ROH) masih menggunakan metode regresi linear sederhana. Penyesuaian perkiraan beban dilakukan berdasarkan *Expert Judgment* yang berbeda beda untuk setiap operator. Hal ini menyebabkan perlunya penyesuaian setiap saat terjadi perubahan realisasi beban. Metode tersebut memiliki batas toleransi error yang cukup besar yaitu 4%. Sehingga diperlukan sebuah model peramalan beban yang mampu menghasilkan data dengan akurasi yang lebih baik [4]. Pada penelitian ini difokuskan untuk peramalan jangka pendek, yaitu untuk jangka waktu harian dengan menggunakan *Long Short Term Memory* (LSTM). Peramalan beban listrik jangka pendek (*Short Term Load Forecasting*) yang akurat sangat dibutuhkan untuk menjaga keandalan penyediaan tenaga listrik [5]. Kegagalan membuat peramalan yang akurat, akan berpotensi menimbulkan gangguan suplai tenaga listrik terutama apabila terjadi perubahan kondisi secara mendadak [6]. Dibandingkan peramalan beban jangka panjang yang perlu memperhitungkan banyak faktor dan menganalisis data lampau yang sangat banyak, peramalan jangka menengah dan jangka pendek lebih sering digunakan untuk peramalan beban.

Metode untuk peramalan beban sudah menjadi objek penelitian yang sering dibahas. Banyak metode yang terus menerus dikembangkan untuk menghasilkan hasil peramalan yang lebih baik. Model peramalan baru terus dikembangkan di seluruh dunia dengan peningkatan menggunakan teknologi komputer dan memanfaatkan teknologi kecerdasan buatan [7]. Secara tradisional, peramalan beban dibuat dengan menggunakan eksplorasi tren data lampau, pembuatan pemodelan ekonomis, ataupun menggunakan teknologi khusus. Metode peramalan tradisional antara lain *regresi linear*, *exponential smoothing*, dan *Autoregressive integrated moving average* (ARIMA). Akan tetapi metode ini kurang mampu menghasilkan peramalan yang akurat terutama apabila data yang ada bersifat seasonal atau memiliki outlier [8]. Sedangkan untuk saat ini, peramalan sudah menggunakan kecerdasan buatan (AI). Salah satunya adalah pengembangan dari Deep Learning Recurrent Neural Network (DLRNN) yaitu Long Short Term Memory (LSTM). Konsep dasar dari LSTM adalah menggabungkan pengetahuan baru (*Short Term Memory* dengan data lampau (*Long Term Memory*) dengan menghapus atau memperbarui data tersebut. LSTM dikembangkan untuk mengatasi kekurangan pada RNN dimana RNN bergantung perubahan bobot data dengan menerima pembaruan secara proporsional terhadap data yang hilang [9]. Metode *Long Short-Term Memory* (LSTM) mempunyai kelebihan dalam pencarian solusi yang akurat dan lebih baik, serta memiliki kemampuan generalisasi dan kemampuan *learning* yang lebih baik untuk himpunan data besar dan kecil, serta data non-linear, dapat dimanfaatkan untuk meningkatkan akurasi peramalan beban listrik jangka pendek.

Penelitian ini bertujuan untuk membuat sebuah model peramalan beban jangka pendek dengan menggunakan

LSTM agar diperoleh sebuah peramalan beban dengan tingkat akurasi yang lebih baik dari kondisi saat ini. Model peramalan tersebut diharapkan dapat menjadi salah satu parameter dalam membuat Rencana Operasi Harian. Untuk memperoleh hasil peramalan sesuai yang diharapkan, pada penelitian ini akan dilakukan beberapa penyesuaian pada parameter LSTM, baik dari pemilihan data *input* dan *tuning* pada *hyper-parameter* yang digunakan[10]. Dari beberapa skenario tersebut nantinya akan ditentukan model yang menghasilkan tingkat akurasi peramalan yang paling akurat.

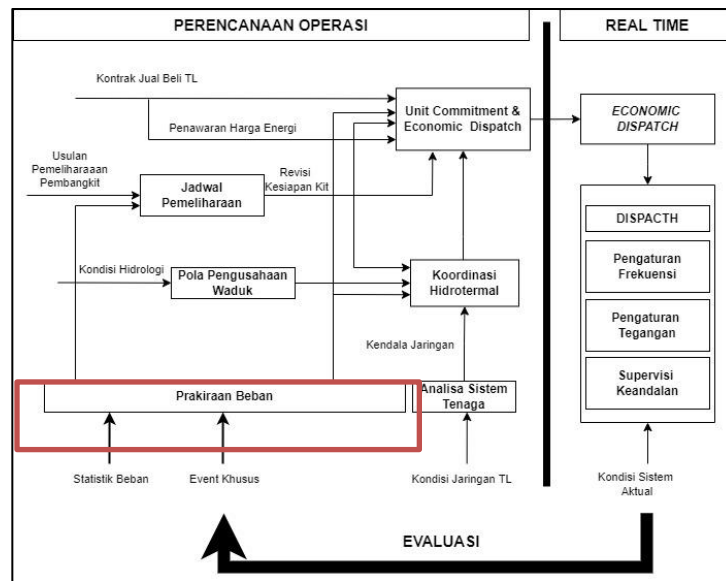
II. METODOLOGI PENELITIAN

Sesuai alur penelitian yang ditunjukkan pada Gambar 3, secara garis besar penelitian ini terbagi menjadi 3 (tiga) tahapan yaitu tahap Pra-pemrosesan data, tahapan pembuatan model LSTM dan tahapan evaluasi hasil simulasi. Data yang digunakan dalam penelitian ini merupakan data realisasi beban harian di sistem Sulawesi Selatan sejak Januari 2017 sampai dengan Juni 2021. Data realisasi beban tersebut menunjukkan realisasi beban listrik harian setiap 30 menit. Seperti dapat dilihat pada Gambar 2, data tersebut termasuk data *time series*[11].


A. Pra-pemrosesan Data

Sebelum mulai menganalisis data, hal pertama yang perlu dilakukan adalah menstandarkan data (normalisasi). Normalisasi adalah proses pengelompokan atribut data agar data yang akan digunakan diyakini memiliki kualitas yang baik. Proses ini perlu dilakukan agar tidak ada inkonsistensi data ataupun *missing value*. Parameter yang berbeda-beda pada suatu *data mining* seringkali menghasilkan data dengan dimensi dan satuan yang berbeda. Sehingga, sebelum dilakukan *training* data perlu dilakukan normalisasi data terlebih dahulu. Setelah dilakukan standarisasi data, maka masing-masing data akan berada pada rentang yang sama. Pada penelitian ini, standarisasi data dilakukan dengan normalisasi min-max [12] sebagaimana dapat dilihat pada persamaan (1).

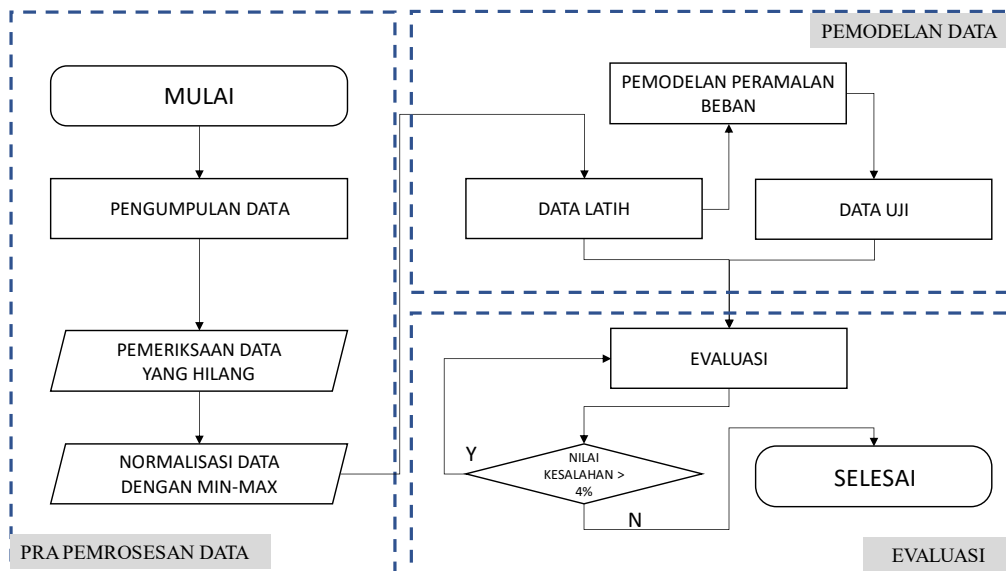
$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$



Gambar 1. Alur Perencanaan Operasi Sistem



Gambar 2. Grafik Variasi Beban per Jam dan Beban Puncak Harian Sistem Sulawesi Selatan



Gambar 3. Diagram Alir Penelitian

B. Pemodelan Data

Data beban yang sudah dinormalisasi, kemudian dimodelkan dengan menggunakan *Long Short Term Memory* (LSTM). *Long Short Term Memory* (LSTM) adalah pengembangan dari *Deep Learning Recurrent Neural Network* (DLRNN). Metode ini digunakan untuk memprediksi data *time series* atau *forecasting*. Prinsip dasar dari LSTM adalah menggabungkan pengetahuan baru (*Short Term Memory*) dengan data lampau (*Long Term Memory*) dengan menghapus atau memperbarui data tersebut. LSTM dikembangkan untuk mengatasi kekurangan pada RNN dimana RNN bergantung perubahan bobot data dengan menerima pembaruan secara proporsional terhadap data yang hilang [9]. Arsitektur model LSTM sebagaimana ditunjukkan pada Gambar 4, terdiri dari *cell state* dan 3 *gate* utama yaitu *forget gate*, *input gate*, dan *output gate*. *Cell state* berperan dalam menyediakan informasi (dari awal hingga akhir data) pada tahap pembentukan model. Informasi yang diberikan pada *cell state* akan dipengaruhi oleh *gate* yang ada seperti *forget gate* dan *input gate*. *Forget gate* berguna buat membuang data yang kurang relevan dengan informasi masukan terkini. Cara pengecekannya memakai fungsi *sigmoid* dari informasi keluaran terdahulu dengan informasi saat ini sehingga diperoleh nilai dari nol hingga satu. Cara ini dilanjutkan dengan melaksanakan operasi berulang terhadap data terkini dengan data lama. Apabila nilai yang diperoleh semakin mendekati nol maka informasi tersebut akan dilupakan[13].

Pada *Input gate*, akan dilakukan pembaruan pada *cell state* dimana akan ditentukan apakah nilai pada informasi yang ada perlu diperbarui atau tidak. Pada *gate* ini dimulai dengan melakukan perhitungan *sigmoid* dan *tanh* pada keluaran data sebelumnya dengan data saat ini. Hasil dari kedua perhitungan tersebut kemudian akan menyimpulkan apakah informasi baru dari perhitungan tersebut apakah perlu disimpan. Hasil yang diperoleh dari proses *input gate* akan ditambahkan pada hasil perhitungan pada *forget gate* untuk memperoleh informasi terbaru dari masukan terbaru. Hasilnya kemudian akan digunakan untuk mendapatkan nilai pada *output gate*. Data tersebut kemudian akan disimpan sebagai hasil keluaran *output gate* pada *cell* tersebut dan akan digunakan sebagai data masukan untuk pemrosesan pada *cell* berikutnya.

Untuk menghasilkan model dengan tingkat eror yang lebih baik dari 4% maka akan dibuat beberapa skenario peramalan, yaitu dengan menggunakan variasi pemilihan masukan data dan penyesuaian pada arsitektur LSTM.

1) Variabel Masukan Data

- Pemodelan dengan menggunakan data pada hari sebelumnya dan data pada hari yang sama pekan sebelumnya.
- Pemodelan dengan menggunakan data hari yang sama di periode sebelumnya
- Pemodelan dengan menggunakan data realisasi beban secara berurutan untuk periode tertentu
- Pemodelan pada tanggal dengan pola tertentu (Ramadan tahun ini dengan tahun-tahun sebelumnya)

2) Arsitektur LSTM

Untuk meningkatkan akurasi model, dapat dilakukan tuning pada arsitektur LSTM. Tuning arsitektur LSTM dapat dilakukan dengan *Hyper-parameter* pada arsitektur LSTM seperti *kernel inializer*, *normalizer*, jumlah *hidden layer*, *dense layer*, *learning rate* maupun fungsi pengaktifan pada LSTM tersebut [10]. Fungsi pengaktifan berperan penting pada jaringan syarat buatan (ANN) untuk mempelajari dan menghubungkan fungsi non linier kompleks antara masukan dan *variabel respon* [14]. Pada beberapa penelitian sebelumnya, fungsi pengaktifan yang paling sering digunakan adalah *sigmoid* dan tangen hiperbolik (*tanh*) [15].

Penelitian terbaru menyatakan bahwa fungsi aktivasi hyper-sinh menunjukkan hasil yang lebih akurat dan reliabel baik untuk *deep learning* maupun *shallow learning* pada TensorFlow dan Keras [16]. Dari beberapa skenario tersebut selanjutnya akan di analisa performa dari masing-masing model.

C. Evaluasi Kinerja Model

Evaluasi kinerja model yang digunakan pada penelitian ini menggunakan indikator nilai MAPE (*Mean Absolute Percentage Error*) dan RMSE (*Root Mean Square Error*) sebagaimana ditunjukkan pada persamaan (2) dan (3). Semakin kecil nilai MAPE, maka tingkat akurasi peramalan dari model yang dibuat semakin baik. RMSE dan MAPE adalah parameter yang sering digunakan untuk mengukur performa dari sebuah model dan sesuai penelitian dari Chai T. dan rekan pada tahun 2014 RMSE lebih baik dalam mengukur performa model dengan data yang terdistribusi normal [17].

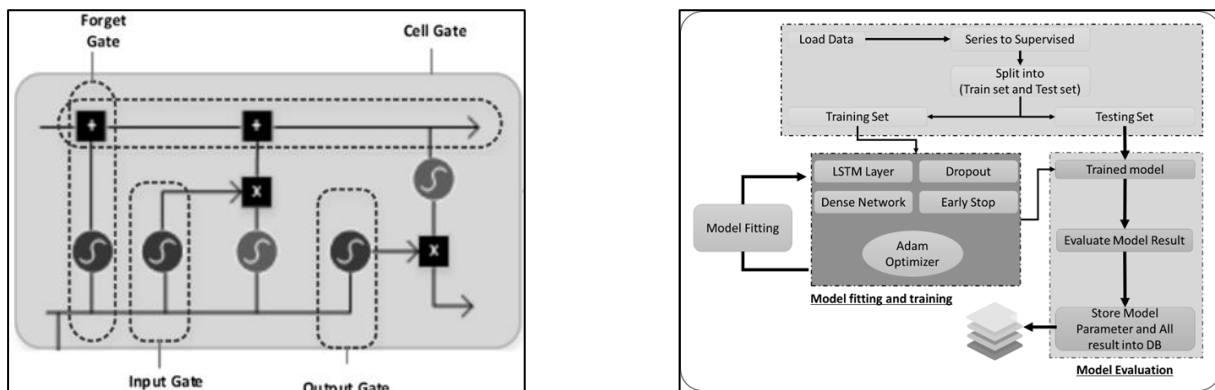
$$MAPE (\%) = \frac{100}{n} \times \sum_{t=1}^n \left| \frac{L_t,measured - L_t,forecast}{L_t,measured} \right| \tag{2}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \tag{3}$$

III. UJI COBA DAN ANALISA

A. Pemilihan Masukan Data

Pada penelitian ini, peramalan beban dilakukan berdasarkan data realisasi beban harian setiap 30 menit di sub sistem Sulawesi Selatan seperti ditunjukkan pada Tabel. 1. Data beban tersebut dimasukkan secara berurutan setiap harinya. Dari data tersebut kemudian dibagi menjadi data latih dan data uji. Peramalan dengan LSTM ini akan digunakan untuk memprediksi beban keesokan harinya (48 keluaran data). Untuk membandingkan model dengan akurasi terbaik, akan dibuat 5 skenario untuk masukan data sebagaimana ditunjukkan pada Tabel. 2. Hasil dari masing-masing skenario tersebut kemudian akan dibandingkan nilai MAPE dan RMSE yang dihasilkan. Sedangkan parameter Arsitektur LSTM yang digunakan dapat dilihat pada Tabel 3.



Gambar 4. Arsitektur Cell LSTM dan Arsitektur Long Short Term Memory (LSTM) [13]

Tabel 1. Data Beban Sistem Sulawesi Selatan

Tanggal	Pukul / Beban (MW)									
	00.30	01.00	01.30	02.00	22.00	22.30	23.00	23.30	24.00
01-01-2017	750.7	739.1	714.1	702.6	817.4	796.0	767.7	737.4	707.6
02-01-2017	671.7	666.7	659.5	652.0	907.5	867.7	839.3	795.2	770.3
03-01-2017	742.5	731.2	720.6	708.4	886.1	851.3	811.8	768.2	755.6
.....
28-09-2021	1054.0	1053.0	1033.0	1025.0	1272.0	1226.0	1171.0	1145.0	1121.0
29-09-2021	1112.0	1090.0	1069.0	1045.0	1272.0	1265.0	1228.0	1182.0	1140.0
30-09-2021	1131.0	1123.0	1115.0	1094.0	1304.0	1247.0	1210.0	1166.0	1141.0

Tabel 2. Skenario Data Masukan

Nama	Input data	Keterangan
------	------------	------------

Skenario 1	Allday	Data beban hari sebelumnya (Senin sampai dengan Minggu) untuk memprediksi beban pada hari tersebut
Skenario 2	Same day (weekday)	Data beban hari yang sama pada pekan-pekan sebelumnya untuk memprediksi beban hari pada tersebut (weekday)
Skenario 3	Same day (weekend)	Data beban hari Sabtu/Minggu pekan-pekan sebelumnya untuk memprediksi beban pada hari Sabtu/Minggu
Skenario 4	Day -1	Data beban hari sebelumnya ditambah data hari yang sama pada pekan sebelumnya untuk memprediksi beban pada hari tersebut
Skenario 5	Hari lebaran	Data hari Lebaran pada tahun sebelumnya untuk memprediksi beban hari Lebaran berikutnya

Tabel 3. Parameter Arsitektur LSTM

Arsitektur	Nilai
Sequence Input Layer	1
LSTM Layer (Stacked LSTM)	7
LSTM Layer	50
Max Epoch	1000
Initial Learn Rate	0.001
Activation Function	Sigmoid

Tabel 4. Performa Hasil Prediksi

Nama	Input data	MAPE	RMSE
Skenario 1	Allday	2.3484	33.95
Skenario 2	Same day (weekday)	4.2423	50.934
Skenario 3	Same day (weekend)	2.9958	42.054
Skenario 4	Day -1	9.596	118.16
Skenario 5	Hari lebaran	12.552	139.84

B. Arsitektur LSTM

Setelah data yang akan digunakan sebagai masukan pada pemodelan LSTM sudah dibersihkan (pemeriksaan *missing value*) maka data tersebut siap untuk digunakan. Agar diperoleh arsitektur LSTM terbaik untuk peramalan beban, dilakukan *mini forecasting* dengan beberapa variasi arsitektur LSTM seperti ditunjukkan pada Tabel 5. Simulasi peramalan ini dilakukan dengan menggunakan data beban 4 hari (4 x 48 data) sebanyak 10 kali simulasi untuk masing-masing arsitektur. Hasil dari simulasi tersebut sebagaimana ditunjukkan pada Tabel 6, kemudian dievaluasi dengan melihat nilai MAPE pada masing-masing simulasi. Dari simulasi ini kemudian dipilih Arsitektur 6 yang akan digunakan untuk pemodelan LSTM. Dari nilai MAPE tersebut, kemudian diambil 50% model dengan nilai MAPE maksimal terkecil untuk selanjutnya diambil 50% model dengan nilai rata-rata MAPE terkecil. Kemudian dari model yang tersisa dipilih model LSTM dengan nilai Standar Deviasi terkecil yang akan digunakan sebagai parameter pada Arsitektur LSTM sebagaimana ditunjukkan pada Tabel 3. Parameter Arsitektur LSTM

C. Analisa Prediksi dengan LSTM

Skenario pengujian pada penelitian ini adalah membandingkan akurasi peramalan dari masing-masing pemilihan masukan data. Dari masing-masing tipe masukan data tersebut kemudian akan dipilih skenario yang mampu menghasilkan peramalan dengan akurasi yang paling baik. Data beban hasil peramalan untuk masing-masing skenario masukan data dapat dilihat pada Tabel 7. Performa hasil simulasi peramalan dengan LSTM sebagaimana ditunjukkan pada Tabel 4, dapat dilihat bahwa skenario 1 memiliki nilai MAPE dan RMSE yang paling baik. Nilai MAPE untuk Skenario 1 menunjukkan bahwa persentase rata-rata eror maksimal adalah sebesar 2,3484%. Lebih baik daripada toleransi eror yang diizinkan yaitu sebesar 4%. Sedangkan nilai RMSE pada skenario 1 menunjukkan bahwa akar rata-rata kuadrat kesalahan pada hasil peramalan adalah sebesar 33,95. Meskipun simulasi dengan data masukan sesuai skenario 3 mampu menghasilkan peramalan yang lebih baik dari

standar acuan, akan tetapi skenario 1 mampu menghasilkan peramalan dengan tingkat kesalahan yang lebih baik. Skenario 1 mampu menghasilkan performa yang lebih baik daripada skenario lain karena masukan data secara berurut setiap hari dapat menggambarkan pola dari konsumsi listrik secara lebih akurat. Lain halnya dengan Skenario 5 yang memiliki performa yang paling buruk, hal ini dapat disebabkan pola konsumsi listrik pada hari lebaran memiliki pola yang berbeda pada setiap tahunnya. Libur lebaran selalu berubah setiap tahun yang dapat mempengaruhi hari kapan masyarakat mulai mudik lebaran.

Tabel 5. Arsitektur mini forecasting LSTM

Arsitektur 1	Arsitektur 2	Arsitektur 3	Arsitektur 4	Arsitektur 5
Eppoch (1000)	Eppoch (1000)	Eppoch (1000)	Eppoch (1000)	Eppoch (1000)
lstmLayer(250)	lstmLayer(25)	lstmLayer(25)	lstmLayer(250)	lstmLayer(250)
DropoutLayer(0.1)	DropoutLayer(0.1)	DropoutLayer(0.25)	DropoutLayer(0.25)	DropoutLayer(0.25)
lstmLayer(300)	lstmLayer(30)	lstmLayer(30)	lstmLayer(300)	lstmLayer(300)
		DropoutLayer(0.25)	DropoutLayer(0.25)	DropoutLayer(0.25)
		lstmLayer(30)	lstmLayer(350)	lstmLayer(350)
		DropoutLayer(0.25)	DropoutLayer(0.25)	
		lstmLayer(35)		
		DropoutLayer(0.25)		
		lstmLayer(40)		
Arsitektur 6	Arsitektur 7	Arsitektur 8	Arsitektur 9	Arsitektur 10
Eppoch (1000)	Eppoch (1000)	Eppoch (1000)	Eppoch (1000)	Eppoch (1000)
lstmLayer(50)	DropoutLayer(0.25)	lstmLayer(250)	lstmLayer(250)	lstmLayer(400)
lstmLayer(50)	lstmLayer(50)	lstmLayer(250)	lstmLayer(300)	lstmLayer(350)
lstmLayer(50)	lstmLayer(50)	lstmLayer(250)	lstmLayer(350)	lstmLayer(300)
lstmLayer(50)	lstmLayer(50)	lstmLayer(250)	lstmLayer(300)	lstmLayer(250)
lstmLayer(50)	lstmLayer(50)	lstmLayer(250)	lstmLayer(250)	lstmLayer(150)
lstmLayer(50)	lstmLayer(50)	lstmLayer(250)	lstmLayer(50)	lstmLayer(100)
lstmLayer(50)	lstmLayer(50)	lstmLayer(250)	lstmLayer(25)	lstmLayer(50)
	lstmLayer(50)		Arsitektur 9	Arsitektur 10
Arsitektur 11	Arsitektur 12	Arsitektur 13	Arsitektur 14	Arsitektur 15
Eppoch (1000)	Eppoch (1000)	Eppoch (1000)	Eppoch (1000)	Eppoch (1000)
lstmLayer(250)	lstmLayer(250)	lstmLayer(100)	lstmLayer(50)	lstmLayer(50)
lstmLayer(300)	lstmLayer(300)	lstmLayer(100)	lstmLayer(50)	lstmLayer(50)
lstmLayer(50)	lstmLayer(350)	lstmLayer(100)	lstmLayer(50)	lstmLayer(50)
lstmLayer(50)	lstmLayer(50)	lstmLayer(100)	lstmLayer(50)	lstmLayer(50)
lstmLayer(50)	lstmLayer(50)	lstmLayer(100)	lstmLayer(50)	lstmLayer(50)
lstmLayer(50)	lstmLayer(50)	lstmLayer(100)	lstmLayer(50)	lstmLayer(50)
lstmLayer(50)	lstmLayer(50)	lstmLayer(100)	lstmLayer(50)	lstmLayer(50)
			lstmLayer(50)	lstmLayer(50)
				lstmLayer(50)

Tabel 6. Nilai MAPE Hasil Simulasi mini forecasting

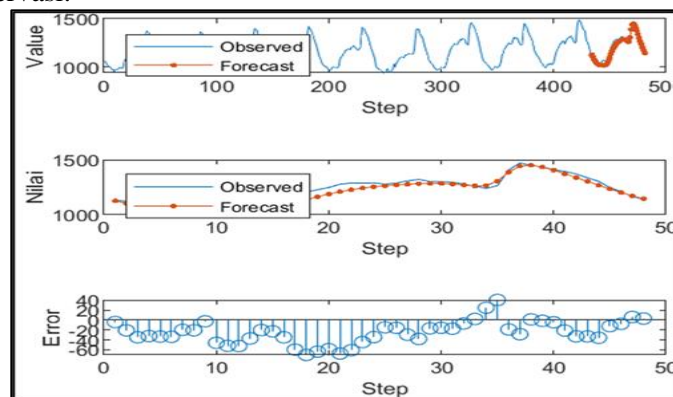
Arsitektur	Avg	Min	Max	Std Dev	Arsitektur	Avg	Min	Max	Std Dev
1	1.875	1.547	2.631	0.302	9	2.745	1.994	5.196	0.848
2	2.243	1.708	2.918	0.364	10	3.721	2.018	7.859	1.866
3	3.181	2.651	3.953	0.429	11	2.342	1.943	2.761	0.306
4	2.266	1.965	2.512	0.156	12	5.265	1.961	12.535	3.402
5	1.997	1.351	2.372	0.273	13	2.978	1.652	8.455	1.989
6	2.219	1.832	2.626	0.267	14	2.334	1.777	3.294	0.503
7	2.830	1.928	4.125	0.570	15	3.129	2.276	3.599	0.397
8	5.430	1.891	22.024	5.977					

Tabel 7. Perbandingan Data Observasi dan Prediksi

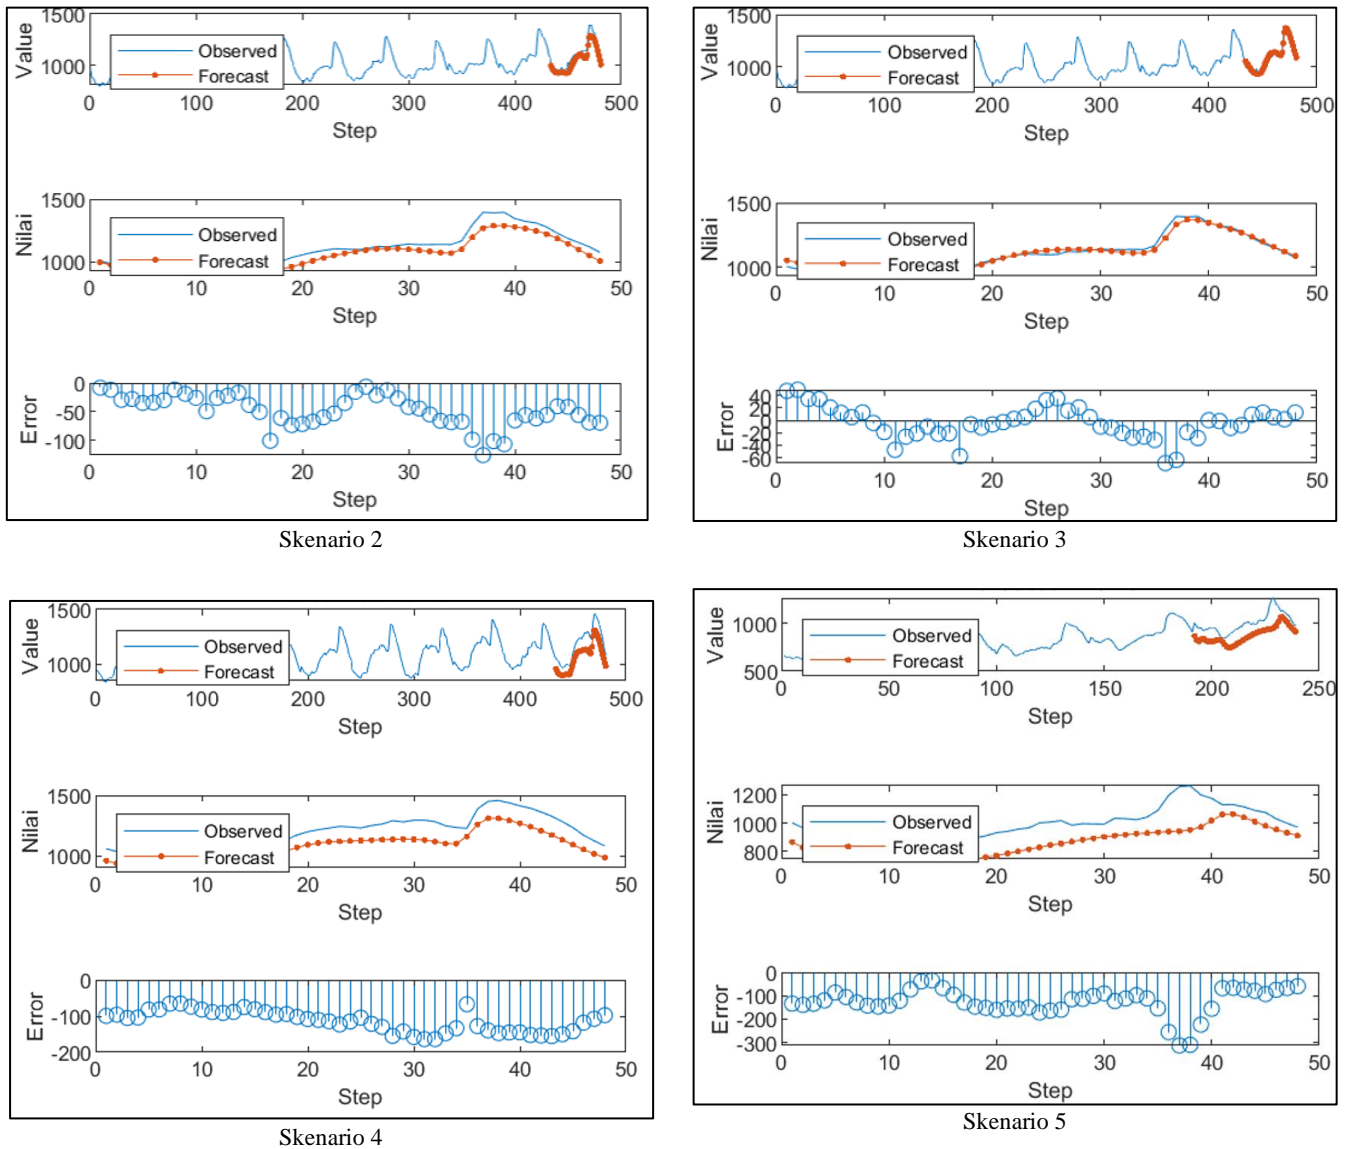
Jam	Skenario 1		Skenario 2		Skenario 3		Skenario 4		Skenario 5	
	Observasi	Prediksi	Observasi	Prediksi	Observasi	Prediksi	Observasi	Prediksi	Observasi	Prediksi
00.30	1131	1127.1	1041	991.26	1008	1065.1	1058	958.68	1001.244	867.28

01.00	1123	1102.2	1020	963.41	988	1046.9	1035	938.93	966.82	827.37
01.30	1115	1080.3	1009	940.86	987	1032	1029	923.86	947.202	812.88
02.00	1094	1061.8	1006	923.47	972	1020.1	1017	913.07	951.12	831.05
02.30	1080	1046.8	999	910.89	970	1011	988	906.07	927.736	841.11
03.00	1069	1035.3	973	902.72	964	1004.3	984	902.33	930.215	824.62
03.30	1047	1027.4	975	898.4	958	999.71	967	901.33	938.597	809.58
04.00	1043	1022.4	951	897.28	940	996.94	968	902.52	950.2431	807.77
04.30	1022	1019.6	970	898.55	949	995.61	979	905.17	956.958	810.89
05.00	1064	1018.2	981	901.36	958	995.28	990	908.07	955.3	813.8
05.30	1069	1017.1	976	904.98	983	995.54	998	909.13	941.766	820.23
06.00	1069	1016.6	985	909.17	960	996.07	998	906.83	902.403	829.68
06.30	1056	1018.9	998	914.55	955	996.71	994	905.53	864.977	826.31
07.00	1048	1027.9	989	922.97	947	997.6	989	914.01	840.241	805.48
07.30	1069	1046.4	988	937.27	966	999.2	1017	936.15	845.971	778.74
08.00	1108	1073.3	991	960.06	978	1002.2	1058	969.02	854.036	757.71
08.30	1164	1104.5	1053	991.86	1033	1007.2	1102	1006	877.26	747.86
09.00	1206	1135.8	1077	1029.7	1005	1014.8	1135	1040.8	895.936	749.12
09.30	1228	1164.5	1062	1067.9	1036	1024.9	1172	1069.6	910.236	758.32
10.00	1248	1189.5	1069	1100.3	1057	1037	1199	1091	932.423	771.71
10.30	1278	1210.6	1092	1122.6	1077	1050.5	1216	1105.5	941.471	786.52
11.00	1289	1228.2	1083	1134.1	1092	1064.4	1229	1114.6	957.256	801.31
11.30	1287	1242.7	1157	1137.6	1105	1077.9	1243	1119.9	966.112	815.69
12.00	1289	1254.7	1147	1137.4	1104	1090.5	1238	1123.1	1001.567	829.73
12.30	1279	1264.4	1158	1137.1	1099	1101.7	1230	1125.7	1007.019	843.53
13.00	1288	1272.3	1165	1138.3	1102	1111.5	1250	1128.7	1017.028	857.03
13.30	1308	1278.5	1201	1141	1125	1119.6	1262	1132.1	985.059	869.98
14.00	1321	1283	1213	1143.7	1120	1125.8	1290	1135.5	995.827	882.04
14.30	1302	1285.3	1206	1144.4	1133	1130.2	1280	1137.4	993.905	892.94
15.00	1300	1284.5	1179	1141	1143	1132.5	1294	1136.3	992.913	902.59
15.30	1297	1279.6	1155	1131.9	1138	1132.8	1294	1130.5	1033.732	911.07
16.00	1278	1271	1158	1117.3	1139	1131.5	1282	1118.4	1030.74	918.51
16.30	1260	1262.3	1146	1101.7	1140	1129.6	1248	1100.7	1022.973	925.04
17.00	1240	1264.8	1140	1102	1139	1129.6	1234	1100.5	1042.638	930.67
17.30	1265	1305.6	1140	1158.3	1169	1138.8	1227	1159.8	1089.6542	935.36
18.00	1407	1388.2	1324	1265.5	1296	1175.1	1387	1259.5	1195.043	939.22
18.30	1471	1442.5	1374	1323.8	1395	1256.1	1450	1310.4	1256.229	943.31
19.00	1449	1450.4	1359	1323.4	1391	1336.2	1457	1310.1	1261.883	951.58
19.30	1435	1433.5	1359	1306.1	1395	1364.4	1437	1291.8	1197.304	973.52
20.00	1410	1405.6	1324	1289.3	1345	1360.6	1413	1268.2	1173.8	1017.8
20.30	1394	1372.8	1303	1274	1323	1345.4	1393	1240.6	1128.548	1060.4
21.00	1371	1338.2	1271	1253.6	1310	1324.8	1362	1208.4	1130.292	1063.6
21.30	1336	1303.1	1225	1223.9	1278	1300	1327	1171.7	1113.398	1039.8
22.00	1304	1268.4	1202	1185.4	1228	1270.7	1282	1131.9	1089.169	1010
22.30	1247	1234.7	1160	1142	1187	1237	1233	1091.2	1074.509	981.29
23.00	1210	1202.5	1124	1097.7	1155	1199.9	1170	1051.8	1029.644	954.91
23.30	1166	1172.2	1095	1055.8	1121	1161.2	1123	1015.5	998.858	931.42
24.00	1141	1144.1	1062	1018.5	1077	1123.2	1081	983.61	970.736	911.4

Sebagaimana ditunjukkan pada Gambar 5-6, data hasil peramalan pada skenario 1 cenderung lebih kecil apabila dibandingkan dengan data observasi. Kecuali pada jam beban puncak (antara pukul 17.00 – 22.00) yaitu pada step 34 sampai dengan 44 terdapat data hasil peramalan yang sedikit di atas dari data observasi. Selain itu pada periode beban puncak, data hasil peramalan cenderung mendekati data observasi. Sedangkan pada skenario 3, tingkat kesalahan data peramalan untuk setiap jamnya lebih bervariasi apabila dibandingkan dengan data observasi. Terdapat hasil peramalan yang melebihi data observasi dan terdapat pula data peramalan yang lebih kecil dibandingkan data observasi.



Gambar 5. Grafik Perbandingan Data Peramalan dan Data Observasi Skenario 1



Gambar 6. Perbandingan Data Peramalan dengan Data Observasi Untuk Skenario 2 - 5

IV. KESIMPULAN DAN SARAN

Nilai MAPE dan RMSE untuk pemodelan dengan masukan data menggunakan skenario 1 lebih kecil apabila dibandingkan dengan masukan data pada skenario yang lain. Oleh karena itu, masukan data yang digunakan untuk pemodelan peramalan beban harian adalah menggunakan data beban setiap hari pada periode sebelumnya. Dengan menggunakan masukan data tersebut, diharapkan tingkat akurasi dari peramalan beban jangka pendek di Sub-sistem Sulawesi Selatan memiliki tingkat akurasi yang lebih baik. Tingkat akurasi peramalan yang baik akan memudahkan *Dispatchers* dalam menyusun Rencana Operasi Harian. Sehingga dapat menyalurkan listrik dengan kualitas yang lebih baik dan biaya pembangkitan yang lebih optimal.

Performa peramalan beban dengan menggunakan model LSTM yang menggunakan Arsitektur dan skenario masukan data tersebut menunjukkan hasil yang lebih baik daripada metode yang digunakan saat ini. Hal ini menunjukkan bahwa penggunaan LSTM untuk peramalan beban mampu menghasilkan akurasi peramalan yang lebih baik daripada metode tradisional. Sesuai dengan hasil peramalan di atas, dari semua skenario masukan data yang digunakan, hasil peramalan pada jam beban puncak cenderung mendekati dengan data observasi. Hal ini dapat disebabkan karena berdasarkan data historis, pada periode beban puncak pola konsumsi listrik memiliki pola yang hampir sama. Sedangkan pada periode di luar beban puncak pola konsumsi listrik lebih bervariasi. Perbedaan tersebut dapat disebabkan oleh kondisi cuaca, aktivitas pelanggan dengan konsumsi besar seperti pabrik, gedung perkantoran, hotel, sarana pendidikan dan lain sebagainya.

Untuk penelitian selanjutnya, peningkatan akurasi peramalan beban dapat memperhitungkan faktor lain seperti cuaca, kondisi ekonomi nasional, kejadian luar biasa yang dapat mengubah pola konsumsi energi listrik, ataupun membuat data masukan berdasarkan kategori tertentu sesuai pola yang memiliki nilai korelasi yang tinggi.

UCAPAN TERIMA KASIH

Atas selesai hingga terbitnya artikel ini, kami sampaikan ucapan terima kasih kepada PLN UIKL Sulawesi yang telah mendukung data yang digunakan pada penelitian ini.

DAFTAR PUSTAKA

- [1] H. Eskandari, M. Imani, and M. P. Moghaddam, "Convolutional and recurrent neural network based model for short-term load forecasting," *Electric Power Systems Research*, vol. 195, Jun. 2021, doi: 10.1016/j.epsr.2021.107173.
- [2] B. Zhao, T. Qian, W. Tang, and Q. Liang, "A data-enhanced distributionally robust optimization method for economic dispatch of integrated electricity and natural gas systems with wind uncertainty," *Energy*, vol. 243, p. 123113, Mar. 2022, doi: 10.1016/J.ENERGY.2022.123113.
- [3] X. Guo, Q. Zhao, S. Wang, D. Shan, and W. Gong, "A Short-Term Load Forecasting Model of LSTM Neural Network considering Demand Response," *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/5571539.
- [4] A. Rafati, M. Joorabian, and E. Mashhour, "An efficient hour-ahead electrical load forecasting method based on innovative features," *Energy*, vol. 201, Jun. 2020, doi: 10.1016/j.energy.2020.117511.
- [5] C. Shang, J. Gao, H. Liu, and F. Liu, "Short-term load forecasting based on PSO-KFCM daily load curve clustering and CNN-LSTM model," *IEEE Access*, vol. 9, pp. 50344–50357, 2021, doi: 10.1109/ACCESS.2021.3067043.
- [6] M. Chazarra, J. I. Pérez-Díaz, J. García-González, and A. Helseth, "Economic effects of forecasting inaccuracies in the automatic frequency restoration service for the day-ahead energy and reserve scheduling of pumped storage plants," *Electric Power Systems Research*, vol. 174, Sep. 2019, doi: 10.1016/j.epsr.2019.04.028.
- [7] J. Lee and Y. Cho, "National-scale electricity peak load forecasting: Traditional, machine learning, or hybrid model?," *Energy*, vol. 239, p. 122366, Jan. 2022, doi: 10.1016/j.energy.2021.122366.
- [8] F. Petropoulos *et al.*, "Forecasting: theory and practice," *International Journal of Forecasting*. Elsevier B.V., 2022. doi: 10.1016/j.ijforecast.2021.11.001.
- [9] H. Khani and H. E. Z. Farag, "Optimal Day-Ahead Scheduling of Power-to-Gas Energy Storage and Gas Load Management in Wholesale Electricity and Gas Markets," *IEEE Transactions on Sustainable Energy*, vol. 9, no. 2, Apr. 2018, doi: 10.1109/TSTE.2017.2767064.
- [10] M. Basirat and P. M. Roth, "Learning Task-specific Activation Functions using Genetic Programming," in *VISIGRAPP 2019 - Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, 2019, vol. 5, pp. 533–540. doi: 10.5220/0007408205330540.
- [11] "Flow chart," *Mathematical Statistics with Applications in R*, p. xxi, Jan. 2021, doi: 10.1016/B978-0-12-817815-7.09001-1.
- [12] J. Du, Y. Cheng, Q. Zhou, J. Zhang, X. Zhang, and G. Li, "Power Load Forecasting Using BiLSTM-Attention," *IOP Conference Series: Earth and Environmental Science*, vol. 440, no. 3, p. 032115, Feb. 2020, doi: 10.1088/1755-1315/440/3/032115.
- [13] R. Indralaksono, A. M. Firdaus, M. A. Wakhid, N. U. Andreas, G. H. Wibowo, and M. Abdillah, "Short-Term Load Forecasting using Long Short-Term Memory Network on Various Sub System Load in PLN Indonesia," in *2021 International Conference on Technology and Policy in Energy and Electric Power (ICT-PEP)*, Sep. 2021, pp. 175–179. doi: 10.1109/ICT-PEP53949.2021.9601005.
- [14] K. Vijayaprabakaran and K. Sathiyamurthy, "Towards activation function search for long short-term model network: A differential evolution based approach," *Journal of King Saud University - Computer and Information Sciences*, 2020, doi: 10.1016/j.jksuci.2020.04.015.
- [15] S. Saha, N. Nagaraj, A. Mathur, and R. Yedida, "Evolution of Novel Activation Functions in Neural Network Training with Applications to Classification of Exoplanets," Jun. 2019, doi: 10.1140/epjst/e2020-000098-9.
- [16] L. Parisi, R. Ma, N. RaviChandran, and M. Lanzillotta, "hyper-sinh: An accurate and reliable function from shallow to deep learning in TensorFlow and Keras," *Machine Learning with Applications*, vol. 6, p. 100112, Dec. 2021, doi: 10.1016/J.MLWA.2021.100112.
- [17] T. Chai, T. Chai, and R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)? Ozone health and ecosystem impacts View project Root mean square error (RMSE) or mean absolute error (MAE)?-Arguments against avoiding RMSE in the literature," *Geosci. Model Dev*, vol. 7, pp. 1247–1250, 2014, doi: 10.5194/gmdd-7-1247-2014.