

Prediksi Besar Daya Listrik dari Gelombang Laut Sawu Menggunakan *Bidirectional Long Short-Term Memory* (Bi-LSTM)

Icha Dwi Safira¹, Dian Candra Rini Novitasari^{2,*}, Nurissaidah Ulinnuha³, Fajar Setiawan⁴

^{1,2,3}Program Studi Matematika, UIN Sunan Ampel Surabaya
Jl. Dr. Ir. H. Soekarno No.682, Kec. Gn. Anyar, Surabaya, Jawa Timur 60294, Indonesia

⁴Forecasting, Stasiun Meteorologi Maritim Perak II Surabaya
Jl. Kalimas Baru No.97B, Kec. Pabean Cantikan, Surabaya, Jawa Timur 60165, Indonesia

¹dwiicha04@gmail.com

³nuris.ulinnuha@uinsby.ac.id

⁴fajar.setiawan@bmkgo.go.id

*Korespondensi: diancrini@uinsa.ac.id

Abstract— Several islands in East Nusa Tenggara Province (NTT) are underdeveloped areas with insufficient electrification. Therefore, renewable energy power plants are needed, namely oscillating water column technology ocean wave power plants (PLTGL-OWC). The objective of this study is to determine the performance of the bidirectional long short-term memory (Bi-LSTM) method in predicting the potential power generated from the height, length, and period of the Sawu Sea waves in NTT using PLTGL-OWC. This study utilises Sawu Sea wave data collected every 12 hours over 9 months. Bi-LSTM is used in this study because it can overcome the vanishing Gradient problem by utilising both the forward layer and the backward layer, making it more effective in solving complex issues, such as time series prediction. This study conducted tests on hyperparameter batch size and hidden layer node configurations. The smallest mean absolute percentage error (MAPE) prediction values obtained were 9.1943% for the wave height parameter, 11.3585% for the wave length parameter, and 7.1485% for the wave period parameter. It means that the Bi-LSTM method is suitable for predicting the electrical power generated by the PLTGL-OWC in the Sawu Sea, as the height and period parameters fall within the MAPE < 10% category, and the length parameter falls within the MAPE 10-20% category. The average electrical power generated is 2,639,865.948 watts per day over a 31-day period. The Sawu Sea has the potential to serve as a renewable energy source in the NTT region.

Keywords— Bi-LSTM, Sawu sea wave, PLTGL-OWC, renewable energy, prediction, power plant

Abstract— Beberapa pulau di Provinsi Nusa Tenggara Timur (NTT) merupakan daerah tertinggal sehingga kurang terpenuhinya kebutuhan elektrifikasi. Oleh karena itu, dibutuhkan pembangkit listrik energi terbarukan, yaitu pembangkit listrik tenaga gelombang laut teknologi *oscillating water column* (PLTGL-OWC). Tujuan dari penelitian ini adalah untuk mengetahui performa metode *bidirectional long short-term memory* (Bi-LSTM) dalam memprediksi potensi besar daya listrik yang dihasilkan dari tinggi, panjang, dan periode gelombang Laut Sawu, NTT menggunakan PLTGL-OWC. Penelitian ini menggunakan data gelombang Laut Sawu yang diambil setiap 12 jam selama periode 9 bulan. Bi-LSTM digunakan pada penelitian ini karena mampu mengatasi masalah *vanishing gradient* dengan memanfaatkan *forward layer* dan *backward layer* yang dimiliki sehingga lebih efektif dalam memecahkan masalah kompleks, seperti prediksi *time series*. Penelitian ini melakukan uji coba *hyperparameter batch size* dan *node hidden layer*. Diperoleh nilai *mean absolute percentage error* (MAPE) prediksi terkecil adalah 9,1943% untuk parameter tinggi gelombang, 11,3585% untuk parameter panjang gelombang, dan 7,1485% untuk parameter periode gelombang. Hal

tersebut berarti bahwa metode Bi-LSTM baik untuk memprediksi daya listrik yang dihasilkan oleh PLTGL-OWC di Laut Sawu karena pada parameter tinggi dan periode termasuk kategori MAPE $< 10\%$ dan pada parameter panjang termasuk kategori MAPE $10\text{-}20\%$. Hasil daya listrik yang dihasilkan rata-rata 2.639.865,948 watt per hari dalam 31 hari. Hal tersebut menunjukkan bahwa Laut Sawu berpotensi sebagai sumber energi terbarukan di NTT.

Kata Kunci— Bi-LSTM, gelombang Laut Sawu, PLTGL-OWC, energi terbarukan, prediksi, pembangkit listrik

I. PENDAHULUAN

Potensi dihasilkannya energi dari laut yang dimiliki Indonesia besar karena Indonesia merupakan negara maritim. Luas wilayah Indonesia sebesar 9,8 juta km², 81% diantaranya adalah laut. Salah satu provinsi yang sebagian besar wilayahnya laut adalah Nusa Tenggara Timur (NTT). Pada Provinsi NTT terdapat satu kota dan dua puluh satu kabupaten yang tersebar di tiga pulau besar dan beberapa pulau kecil. Beberapa pulau di Provinsi NTT merupakan daerah tertinggal karena letaknya yang terpencil sehingga kurang tersentuh pembangunan dan kurang terpenuhinya kebutuhan elektrifikasi [1]. Berdasarkan Statistik Ketenagalistrikan 2020, rasio elektrifikasi NTT adalah 87,62%. Angka tersebut merupakan angka rasio elektrifikasi terendah di Indonesia [2]. Rasio elektrifikasi tersebut menggambarkan tingkat ketersediaan daya listrik bagi masyarakat. Namun, NTT memiliki potensi energi alternatif yang sangat besar sehingga dapat digunakan sebagai sumber energi terbarukan untuk mendirikan pembangkit listrik. Jika pemanfaatan energi terbarukan di NTT berjalan dengan baik, kemungkinan besar NTT akan mengatasi masalah defisitnya [3]. Oleh karena itu, dibutuhkan pembangkit listrik dengan sumber terbarukan di Provinsi NTT untuk mengatasi rendahnya rasio elektrifikasi salah satunya dari laut itu sendiri, yaitu gelombang laut. Di wilayah perairan NTT, khususnya Laut Sawu memiliki gelombang yang cukup tinggi dan stabil sehingga berpotensi untuk dijadikan pembangkit listrik alternative, yaitu dengan pemanfaatan tinggi, panjang, serta periode gelombangnya. Daya listrik yang dimanfaatkan diperoleh dari gelombang laut yang menghasilkan energi kinetik serta energi potensial melalui Pembangkit Listrik Tenaga Gelombang Laut Teknologi *Oscillating Water Column* (PLTGL-OWC) [4]. Energi tersebut yang nantinya sebagai pemasok daya listrik kepada konsumen. Potensi Laut Sawu sebagai pembangkit listrik alternatif dapat dilihat dari prediksi besar daya listrik yang dihasilkan. Metode yang bisa diaplikasikan untuk prediksi salah satunya, yaitu *bidirectional long short-term memory* (Bi-LSTM).

Forward dan *backward* merupakan *input* yang dimiliki oleh Bi-LSTM. Dengan dua *input* tersebut, sistem kemungkinan mampu mempelajari informasi masa mendatang dan masa lalu [5]. Bi-LSTM merupakan metode pengembangan dari metode *Long Short-Term Memory* (LSTM). LSTM adalah perkembangan dari *recurrent neural network* (RNN) yang menjadi solusi dari permasalahan *vanishing gradient* dalam RNN yang menyebabkan RNN tidak dapat mempelajari dengan benar [6]. LSTM diciptakan untuk mengurangi ketergantungan jangka panjang pada algoritma RNN [7]. LSTM bisa mempelajari mana data yang akan dibuang dan mana data yang memungkinkan untuk disimpan [8], tetapi LSTM memiliki kelemahan hanya bisa mempelajari dari arah maju (*forward*). Oleh karena itu, diciptakanlah metode Bi-LSTM yang berguna untuk memecahkan masalah yang kompleks, seperti prediksi *time series*, pengenalan tulisan tangan, dan deteksi ucapan [9].

Beberapa penelitian terdahulu melakukan prediksi daya listrik berdasarkan gelombang laut. Terdapat penelitian yang memprediksi besar daya listrik di Banyuwangi dengan PLTGL-OWC menggunakan metode *extreme learning machine* (ELM) [10]. Kekurangan ELM yaitu tidak memiliki kemampuan untuk menangani data sekuensial atau temporal karena ELM tidak dirancang untuk dapat memproses ketergantungan jangka panjang, seperti data *time series*, sedangkan Bi-LSTM dapat mengatasi kekurangan

tersebut dengan *forward* dan *backward layer* yang dimilikinya [11] [12]. Penelitian lain melakukan prediksi besar daya listrik di perairan pantai utara Kabupaten Sambas, Kalimantan Barat yang diperoleh dari data angin yang dikonversi menjadi parameter gelombang laut (tinggi, panjang, dan periode) menggunakan metode SPM 1984 dan *software* CEDAS. Parameter tersebut kemudian digunakan untuk menghitung energi gelombang linear yang selanjutnya dikonversikan menjadi daya listrik [13]. Metode SPM 1984 dan *software* CEDAS merupakan model empiris konvensional yang hanya bisa memprediksi dengan baik pada kondisi ideal (linear dan stabil) [14]. Sementara itu, Bi-LSTM dapat mengatasi pola non-linear menggunakan fungsi aktivasi nonlinear (*sigmoid* dan *tanh*) yang ada di dalam arsitekturnya [15]. Penelitian lain menguji performa metode *random forest* dengan melakukan prediksi besar daya listrik di Mutriku Wave Farm berdasarkan data WEF dari model fisika (ECMWF), listrik aktual yang dihasilkan di Mutriku, dan data EOFs atmosfer dan oseanik [16]. Sama seperti ELM, metode *Random Forest* tidak memiliki kemampuan untuk menangani data sekuensial atau temporal [17]. Metode-metode yang digunakan dalam penelitian terdahulu masing-masing memiliki kekurangan. Kekurangan pada setiap metode tersebut memberikan ruang untuk metode Bi-LSTM untuk mengatasi kekurangan yang ada.

Penelitian yang melakukan perbandingan metode Bi-LSTM dengan metode yang lain di antaranya penelitian yang membandingkan metode BP, ELMAN, RNN, UNI-LSTM, dan Bi-LSTM untuk prediksi lalu lintas jalan bebas hambatan yang hasilnya, Bi-LSTM paling unggul dengan MAPE masing-masing 4,32%, 5,56%, 9,49%, 5%, dan 1,54% [15]. Penelitian lain membandingkan LSTM dan Bi-LSTM untuk prediksi harga batu bara yang hasilnya Bi-LSTM lebih unggul dari LSTM dengan MAPE Bi-LSTM 7,847% dan MAPE LSTM 10,442% [18]. Penelitian lain membandingkan LSTM, GRU, dan Bi-LSTM untuk prediksi harga mata uang kripto yang hasilnya Bi-LSTM paling unggul dengan MAPE parameter BTC masing-masing 1,31%, 1,18%, dan 1,16%; MAPE parameter ETH masing-masing 1,30%, 1,21%, dan 1,16%; dan MAPE parameter BNB masing-masing 1,26%, 1,16%, dan 10,08% [19].

Penelitian yang telah dijelaskan sebelumnya menunjukkan bahwa metode Bi-LSTM unggul untuk prediksi, akan tetapi metode Bi-LSTM belum pernah digunakan pada data gelombang Laut Sawu. Oleh karena itu, tujuan dilakukannya penelitian ini yaitu untuk mengetahui performa metode Bi-LSTM dengan melakukan prediksi terhadap potensi besar daya listrik yang dihasilkan Laut Sawu, NTT menggunakan PLTGL-OWC. Dengan demikian, hasil dari prediksi tersebut dapat digunakan untuk pemanfaatan Laut Sawu sebagai penyumbang energi terbarukan bagi masyarakat NTT yang dapat meningkatkan rendahnya rasio elektrifikasi.

II. METODOLOGI

A. Tahapan Penelitian

Langkah-langkah yang dilakukan dalam penelitian ini diperlihatkan dalam bentuk diagram alir pada Gambar 1. Langkah perhitungan dimulai dari data yang telah diperoleh dilakukan *preprocessing* yang diawali dengan interpolasi kemudian dilakukan proses normalisasi data. Setelah itu, dilakukan pembentukan data menjadi data deret waktu (*time series*) kemudian data dibagi untuk pelatihan (*training*) dan pengujian (*testing*). Pada data *training* didapatkan model Bi-LSTM yang akan disimpan kemudian dibuat model LSTM untuk *testing* data. Setelah itu, didapat hasil prediksi yang kemudian akan dinormalisasi dan dievaluasi menggunakan *mean absolute percentage error* (MAPE).

B. Data Penelitian

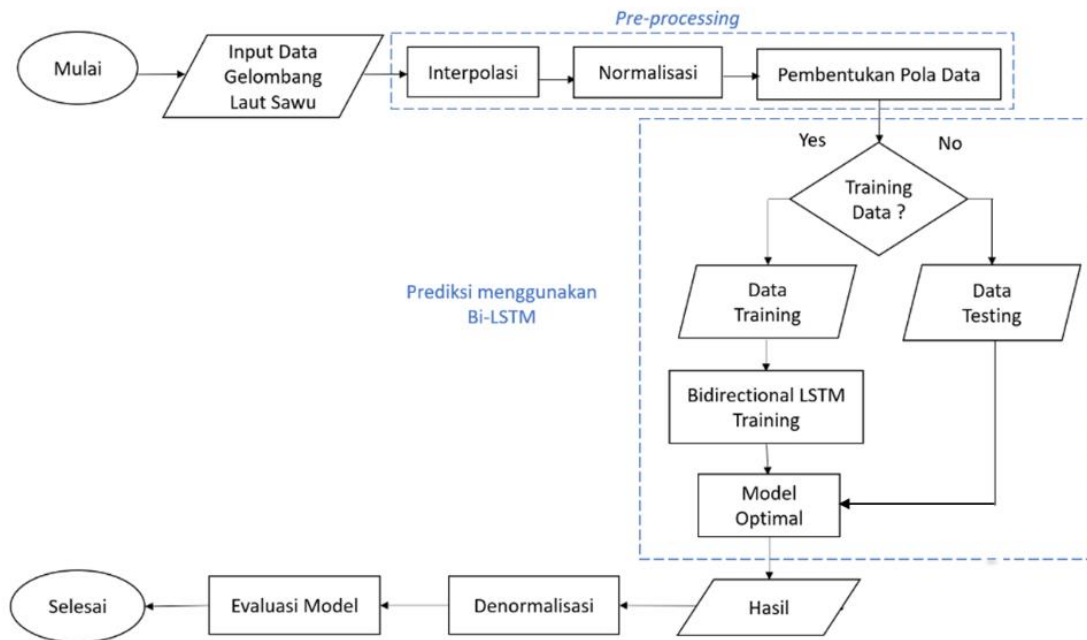
Data yang diolah pada penelitian ini didapatkan dari Badan Stasiun Meteorologi Maritim Perak II Surabaya. Data tersebut berupa data gelombang di Laut Sawu, Nusa Tenggara Timur (NTT) setiap 12 jam

yang dimulai tanggal 1 Januari 2021 sampai 30 September 2022. Tabel I menunjukkan sampel data gelombang yang diolah pada penelitian ini.

Data tersebut kemudian diprediksi menggunakan metode Bi-LSTM dengan langkah-langkah pada Gambar 1. Hasil prediksi dari masing-masing variabel tersebut kemudian dihitung menggunakan metode PLTGL-OWC untuk menghitung daya listrik.

C. Pembangkit Listrik Tenaga Gelombang Laut Oscillating Water Column (PLTGL-OWC)

Sistem yang dapat mengkonversi energi listrik dari gelombang laut salah satunya adalah *oscillating water column* (OWC). Prinsip kerjanya adalah lubang pintu OWC menangkap energi gelombang yang dapat menyebabkan ketidakstabilan gerakan di dalam kolom OWC kemudian menghasilkan tekanan udara. Tekanan udara tersebut membuat baling-baling turbin yang terhubung pada generator listrik menjadi gerak dan mampu menghasilkan listrik [20] [10]. Agar gerakan keluar-masuk udara pada *chamber* menghasilkan putaran yang searah, maka kedua turbin tersebut disusun dengan kemiringan letak medan turbin yang berlawanan arah. Besar daya listrik dipengaruhi oleh ukuran pada *chamber*. Semakin besar luas *chamber*, maka akan menghasilkan energi listrik yang semakin besar [21]. Rumus konversi energi listrik yang didapatkan dari gelombang laut dengan menerapkan PLTGL-OWC terdapat pada Persamaan (1) [22].



Gambar 1 Diagram alir penelitian

TABEL I
SAMPel DATA GELOMBANG LAUT SAWU

Tanggal	Tinggi (m)	Panjang (m)	Periode (m)
00/01/01/2021	1,4602	386,7088	15,1163
12/01/01/2021	1,5310	368,8618	15,1381
00/02/01/2021	1,4021	332,8515	14,3876
12/02/01/2021	1,3436	287,9363	13,2668
00/03/01/2021	1,2966	229,2392	11,3916

12/03/01/2021	1,1297	218,4209	11,2743
---------------	--------	----------	---------

$$Pw = \frac{\frac{1}{2} \times \rho \times g \times w \times a^2 \times \lambda}{T} \quad (1)$$

$$a = \frac{h}{2} \quad (2)$$

Pw adalah daya listrik (watt), ρ adalah massa jenis air (air laut = 1030 kg/m³), g adalah gaya gravitasi bumi (9,81 m/s), w adalah luas *chamber*, a adalah amplitudo gelombang, λ adalah panjang gelombang, dan T adalah periode gelombang. Nilai a diperoleh dari perhitungan menggunakan Persamaan (2), di mana h merupakan tinggi gelombang.

D. Bidirectional Long Short-Term Memory (Bi-LSTM)

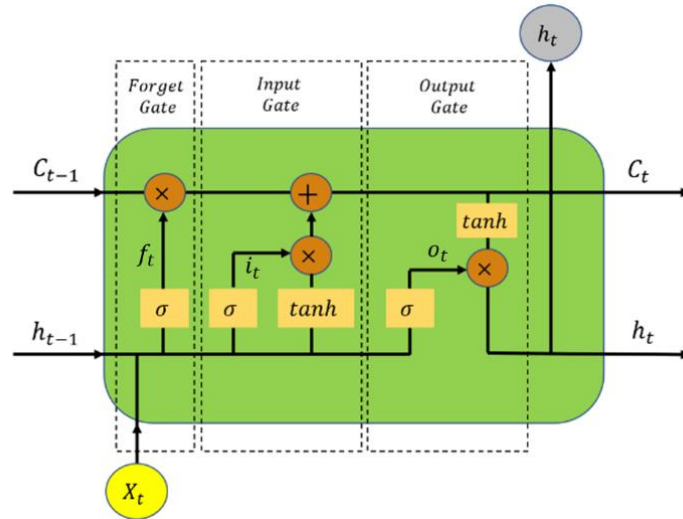
Bidirectional Long Short-Term Memory (Bi-LSTM) adalah bentuk dari pengembangan *long short-term memory* (LSTM). LSTM diciptakan untuk mengurangi ketergantungan jangka panjang pada algoritma RNN [7]. LSTM bisa mempelajari data yang akan dibuang atau data yang memungkinkan untuk disimpan karena setiap neuron LSTM terdapat *gate* yang mengatur memori dari setiap neuron itu sendiri [8]. Gambar 2 menunjukkan arsitektur LSTM.

Pada arsitektur LSTM terdapat tiga buah *gate*, di mana f_t merupakan *forget gate*, i_t merupakan *input gate*, dan o_t merupakan *output gate* [23]. Persamaan untuk setiap *gate* ditunjukkan pada Persamaan (3)-(8) [8]. *Forget gate* adalah *gate* yang memutuskan *input* dan *output* akan diteruskan ke *cell state* atau tidak [24]. Persamaan (2) merupakan perhitungan untuk *forget gate*.

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (3)$$

f_t adalah *forget gate*, σ adalah fungsi sigmoid, W_f adalah bobot pada *forget gate*, h_{t-1} adalah *output* dari waktu $t - 1$, x_t adalah data *input* pada waktu t , dan b_f adalah bias dari *forget gate*.

Proses selanjutnya adalah menyeleksi informasi yang akan dipertahankan pada *cell state* [25], yaitu dengan menambahkan nilai kandidat baru \hat{C}_t dan memperbarui informasi pada *input gate* i_t . Terakhir adalah menentukan *hidden state output* h_t [26].



Gambar 2 Arsitektur LSTM

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\hat{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad (5)$$

Persamaan (6) adalah *cell state gate* untuk memperbarui nilai C_{t-1} yang lama ke nilai C_t yang baru.

$$C_t = f_t \times C_{t-1} + i_t \times \hat{C}_t \quad (6)$$

Nilai *output* didapatkan dari nilai yang dipilih oleh *sigmoid gate*.

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \times \tanh(C_t) \quad (8)$$

Tanh digunakan untuk mendapat nilai dalam rentang -1 hingga 1, W_i adalah bobot *input gate*, b_i adalah bias *input gate*, \hat{C}_t adalah kandidat nilai baru yang ditambahkan di *cell state*, W_c adalah bobot *cell state*, b_c adalah bias *cell state*, o_t adalah nilai *output gate*, W_o adalah bobot *output gate*, b_o adalah bias *output gate*, h_t adalah *final output* pada waktu ke t , dan C_t adalah *cell state*.

Model LSTM hanya bisa menyebarkan informasi ke depan. Akibatnya, keadaan waktu t berdasarkan informasi pada masa lalu saja [27]. Untuk itu, diperkenalkan metode *bidirectional long short-term memory* (Bi-LSTM). Arsitektur Bi-LSTM dengan *hidden layer* yang terpisah (*forward layer* dan *backward layer*) dapat dilatih di kedua arah secara bersamaan [28]. Gambar 3 merupakan arsitektur Bi-LSTM.

Forward layer pada arsitektur Bi-LSTM sama dengan konsep LSTM yang melakukan perhitungan dengan urutan dari $t - 1$, t , lalu $t + 1$, tetapi *backward layer*, *hidden layer*, dan *output* dihitung dari $t + 1$, t ke $t - 1$. *Output* dari kombinasi *hidden layer* \vec{h}_t dan \overleftarrow{h}_t yaitu Persamaan (8) [29].

$$y_t = U_y \vec{h}_t + W_y \overleftarrow{h}_t + b_y \quad (8)$$

y_t adalah *output gate* Bi-LSTM. U_y adalah bobot untuk *output gate* pada \vec{h}_t dan \vec{h}_t merupakan *output* pada LSTM *forward*. W_y adalah bobot untuk *output gate* pada \vec{h}_t dan \vec{h}_t merupakan *output* pada LSTM *backward*.

E. Mean Absolute Percentage Error (MAPE)

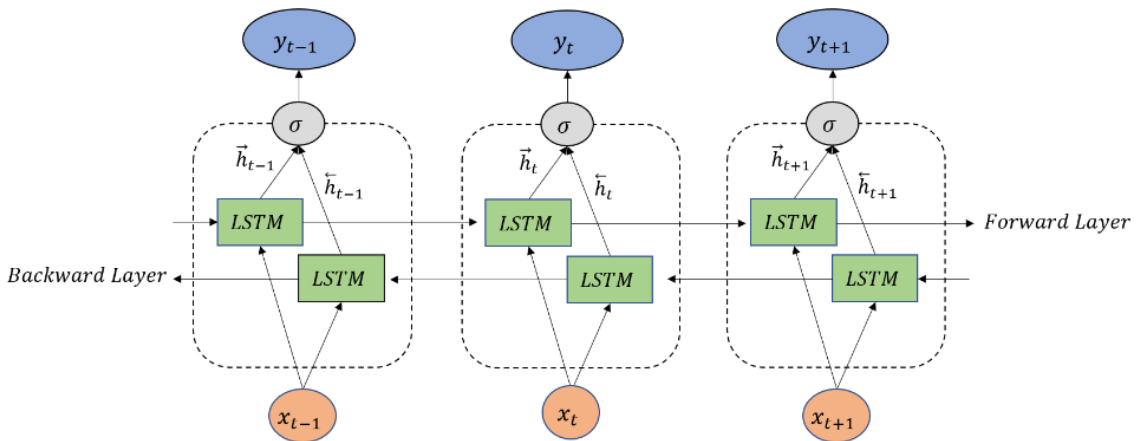
Mean absolute percentage error (MAPE) menunjukkan seberapa besar kesalahan (tingkat *error*) dalam prediksi dibandingkan dengan nilai aktualnya [30]. MAPE merupakan metode pengukuran hasil prediksi yang paling banyak digunakan karena kemampuannya dalam menghitung rata-rata kesalahan prediksi secara relatif [31]. Besar *error* dari hasil prediksi dapat dihitung menggunakan MAPE dengan rumus pada Persamaan (9) [24].

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right|}{n} \times 100\% \tag{9}$$

Y_i merupakan nilai aktual data ke- i , \hat{Y}_i merupakan nilai hasil prediksi data ke- i , dan n merupakan jumlah data. Semakin rendah nilai MAPE yang diperoleh dari hasil prediksi, maka semakin optimal prediksi yang dihasilkan sesuai dengan kriteria nilai MAPE, diperlihatkan pada Tabel II [32].

III. HASIL DAN PEMBAHASAN

Jumlah data yang diolah pada penelitian ini yaitu 1.276 data dengan sampel data yang ditunjukkan pada Tabel 1. Data tinggi, panjang, dan periode gelombang digunakan sebagai parameter untuk memprediksi daya listrik. Data gelombang Laut Sawu yang dikumpulkan dari BMKG Perak II Surabaya memiliki 3,369% nilai yang hilang. Oleh karena itu, perlu dilakukan *preprocessing* yang dimulai dari proses interpolasi yang digunakan pada penelitian ini untuk mengisi data-data yang hilang tersebut [33]. Setelah dilakukan interpolasi, langkah *preprocessing* selanjutnya adalah menormalisasi setiap parameter. Tabel III menunjukkan hasil dari normalisasi setiap parameter data gelombang Laut Sawu.



Gambar 3 Arsitektur Bi-LSTM [34]

TABEL II

KRITERIA NILAI MAPE

MAPE	<10%	10-20%	20-50%	>50%
Kemampuan Prediksi	Sangat Baik	Baik	Cukup Baik	Buruk

TABEL III

SAMPEL NORMALISASI DATA

Tinggi	Panjang	Periode
0,2558	0,9900	0,9673
0,2746	0,9384	0,9693
0,2404	0,8342	0,8990
0,2249	0,7043	0,7939
0,2125	0,5345	0,6182
0,1682	0,5032	0,6072

Jenis normalisasi yang digunakan yaitu normalisasi *min-max* [35][36]. Normalisasi *min-max* diterapkan pada penelitian ini untuk melakukan perubahan pada data yang memiliki interval nilai terlalu jauh menjadi antara 0 sampai 1. Normalisasi dilakukan agar setiap parameter memiliki skala yang seragam karena rentang yang terlalu besar antar parameter akan mengalami kesulitan untuk mencapai konvergen [37]. Jaringan Bi-LSTM dilatih oleh *input* data dan variabel target. Untuk itu dilakukan uji coba dalam proses penyusunan pola *time series* dari data total gelombang harian. Pada penelitian ini, setiap parameter diuji coba menggunakan metode Bi-LSTM secara terpisah menggunakan pola 1 sampai pola 7 untuk menentukan pola yang paling optimal pada masing-masing parameter, serta untuk menghindari adanya parameter yang *underfit* (pola terlalu pendek) atau *overfit* (pola terlalu panjang) [38][39][40][41]. Penggunaan pola series adalah karena telah terbukti optimal dalam prediksi LSTM [42].

Tabel IV merupakan hasil uji coba pola *time series* pada masing-masing parameter. Data target dari uji coba adalah data yang berurutan setelah data input. Tabel V hingga Tabel VII menunjukkan variabel *input* dan target pada setiap parameter. Tabel V artinya untuk mendapatkan hasil prediksi tinggi gelombang satu hari ke depan, maka dibutuhkan data empat hari sebelumnya. Tabel VI artinya untuk mendapatkan hasil prediksi tinggi gelombang satu hari ke depan, maka dibutuhkan data enam hari sebelumnya. Tabel VII artinya untuk mendapatkan hasil prediksi periode gelombang satu hari ke depan, maka dibutuhkan data tujuh hari sebelumnya.

Data yang sudah berpola kemudian dibagi menjadi 2 bagian, yaitu data *training* yang digunakan untuk proses *training* dan data *testing* yang digunakan untuk proses *testing*. Pembagian data pada penelitian ini yaitu 90:10 yang artinya 90% dari total data digunakan untuk proses *training*, sedangkan 10% sisanya digunakan untuk proses *testing*. Terdapat 1.148 data *training* yang dimulai dari 1 Januari 2022 sampai 28 Juli 2022 dan 128 data *testing* yang dimulai dari 29 Juli sampai 30 September 2022.

TABEL IV

HASIL UJI COBA POLA *TIME SERIES*

Pola	MAPE (%)		
	h	λ	T
1	13,2375	12,9234	8,9345
2	11,5182	13,1256	7,8123

3	13,8237	11,9234	7,6234
4	10,9124	12,5123	8,7123
5	12,3071	13,0034	7,8345
6	12,7123	11,7127	8,5432
7	11,8215	12,2156	7,4123

TABEL V
POLA DATA INPUT PARAMETER H

Data h	Target
h_1, h_2, h_3, h_4	h_5
h_2, h_3, h_4, h_5	h_6
\vdots	\vdots
$h_{1272}, h_{1273}, h_{1274}, h_{1275}$	h_{1276}

Bi-LSTM memiliki beberapa *hyperparameter* yang jika dikombinasikan dapat mempengaruhi kemampuannya dalam melakukan prediksi. *Hyperparameter* tersebut adalah *node hidden layer* dan *batch size*. Pada Bi-LSTM, *tuning hyperparameter node hidden layer* dan *batch size* memberikan pengaruh signifikan terhadap stabilitas pelatihan (*training*) dan akurasi prediksi. Hal tersebut menunjukkan bahwa tidak semua *hyperparameter* perlu di-*tuning* secara bersamaan karena *hyperparameter* lain yang ditetapkan sudah memiliki nilai yang efektif [43].

Node hidden layer menyatakan banyaknya *node* yang ada di dalam *hidden layer* secara langsung memengaruhi kemampuan model mendeteksi pola dalam data, sedangkan *batch size* merupakan jumlah sampel yang diproses sebelum pembaruan bobot pada jaringan [43]. *Node hidden layer* yang digunakan untuk uji coba pada penelitian ini yaitu 5, 15, 50, dan 100, sedangkan *batch size* yang digunakan untuk uji coba pada penelitian ini yaitu 4, 8, 12, dan 16. Pemilihan angka *node hidden layer* berdasarkan penelitian terdahulu yang menyatakan bahwa angka tersebut optimal dalam menghasilkan akurasi yang tinggi untuk prediksi [44][45][46]. Sementara itu, pemilihan angka *batch size* adalah faktor 2 (2^n dengan n adalah bilangan asli) karena memori pada GPU berbentuk blok yang optimal untuk ukuran faktor 2 sehingga dapat mempercepat komputasi [47]. Selain itu, *batch size* kecil telah terbukti menghasilkan generalisasi yang lebih baik dan lebih efektif dibandingkan dengan *batch size* besar [48][49]. Hasil dari berbagai kombinasi *hyperparameter* tersebut kemudian dianalisis untuk mengevaluasi kinerja model. Tabel VII menunjukkan hasil uji coba *hyperparameter*.

Tabel VIII menyajikan nilai MAPE yang dihasilkan dari beberapa kali *running*. Hasil dari beberapa kali *running* tersebut menunjukkan bahwa nilai MAPE terendah pada parameter h , λ , dan T masing-masing yaitu 9,1943%, 11,3585%, dan 7,1485% pada penggunaan *node hidden layer* sebanyak 5 dan *batch size* 4, sedangkan nilai MAPE terbesar pada parameter h , λ , dan T masing-masing yaitu 13,4545% pada *node hidden layer* 5 dan *batch size* 16, 12,4799% pada *node hidden layer* 100 dan *batch size* 16, dan 7,3953% pada *node hidden layer* 15 dan *batch size* 16. Dari Tabel VII dapat diketahui bahwa semakin kecil *batch size*, maka semakin rendah juga nilai MAPE yang diperoleh. Hal tersebut menunjukkan bahwa penggunaan

TABEL VI
POLA DATA INPUT PARAMETER λ

Data λ	Target
----------------	--------

$\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5, \lambda_6$	λ_7
$\lambda_2, \lambda_3, \lambda_4, \lambda_5, \lambda_6, \lambda_7$	λ_8
\vdots	\vdots
$\lambda_{1270}, \lambda_{1271}, \lambda_{1272}, \lambda_{1273}, \lambda_{1274}, \lambda_{1275}$	λ_{1276}

TABEL VII

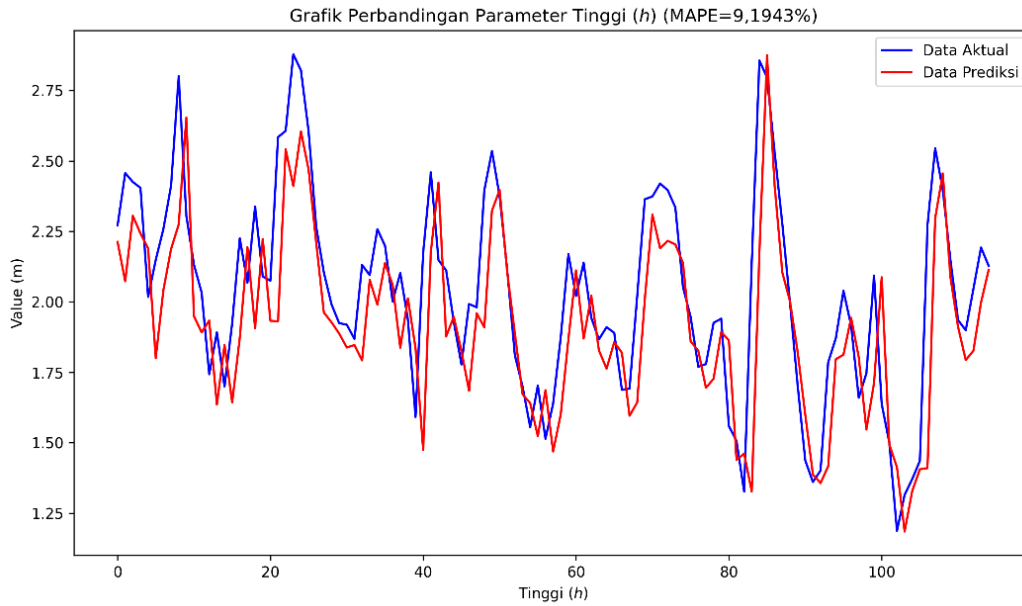
POLA DATA *INPUT* PARAMETER T

Data T	Target
$T_1, T_2, T_3, T_4, T_5, T_6, T_7$	T_8
$T_2, T_3, T_4, T_5, T_6, T_7, T_8$	T_9
\vdots	\vdots
$T_{1269}, T_{1270}, T_{1271}, T_{1272}, T_{1273}, T_{1274}, T_{1275}$	T_{1276}

TABEL VIII

HASIL UJI COBA HYPERPARAMETER

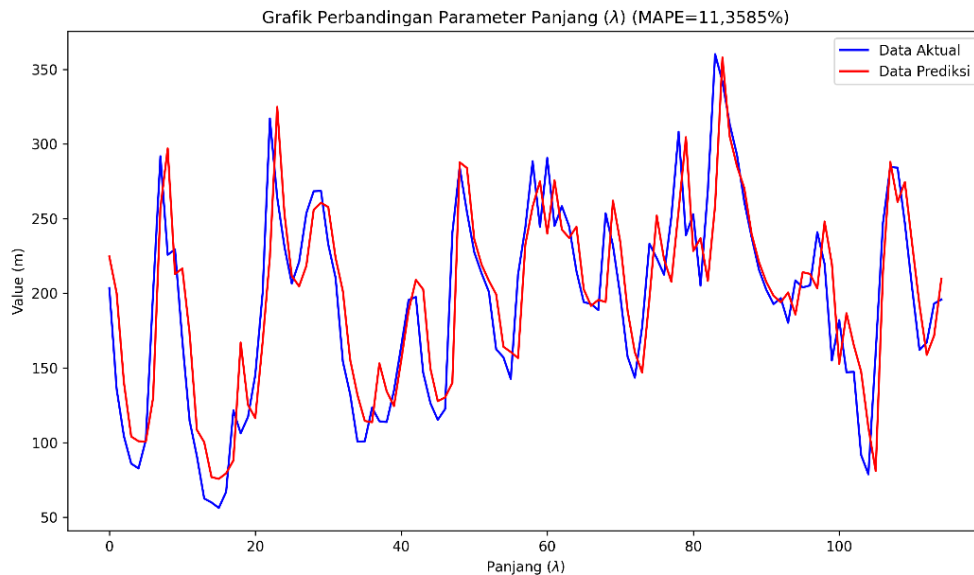
Hyperparameter		MAPE (%)		
Node Hidden Layer	Batch Size	h	λ	T
5	4	9,1943	11,3585	7,1485
	8	10,1416	11,6785	7,1997
	12	12,3511	11,7876	7,2365
	16	13,4545	12,3412	7,3065
15	4	9,8754	11,5365	7,1576
	8	10,9516	11,8292	7,2084
	12	12,3281	12,0942	7,2211
	16	13,2836	12,2764	7,3953
50	4	9,8930	11,5524	7,1883
	8	11,3428	11,7799	7,2563
	12	12,4118	11,9116	7,3924
	16	13,2018	12,3361	7,5145
100	4	9,6841	11,6686	7,1814
	8	11,1248	11,7274	7,2528
	12	12,2885	12,0224	7,3665
	16	13,2989	12,4799	7,5330



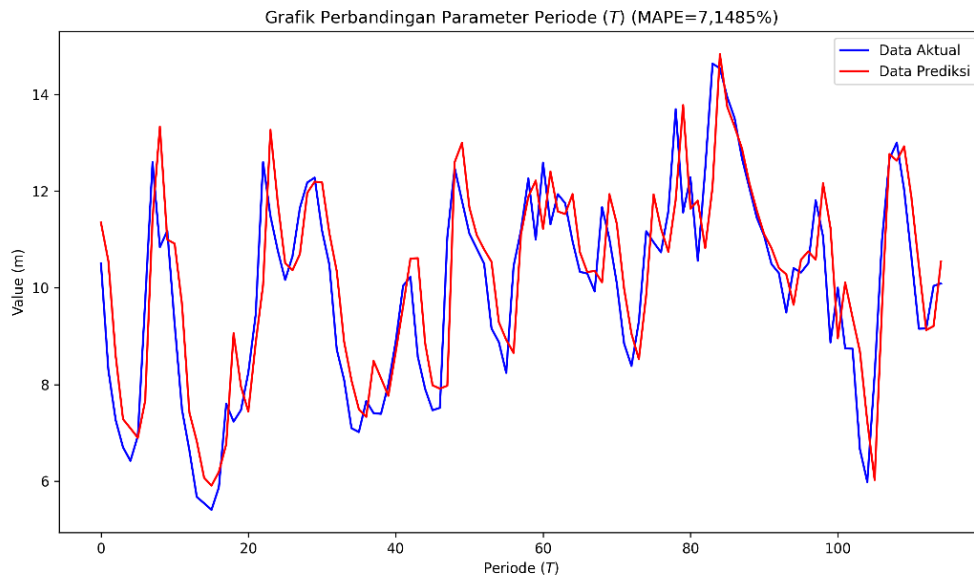
Gambar 4 Grafik hasil prediksi parameter tinggi

batch size kecil cenderung menghasilkan prediksi yang lebih akurat. Gambar 4, 5, dan 6 menunjukkan bahwa model yang digunakan mampu merepresentasikan pola masing-masing parameter dengan sangat baik. Perbedaan tipis antara grafik data aktual dan data prediksi mengindikasikan bahwa nilai error kecil sehingga tingkat akurasi prediksi tergolong tinggi.

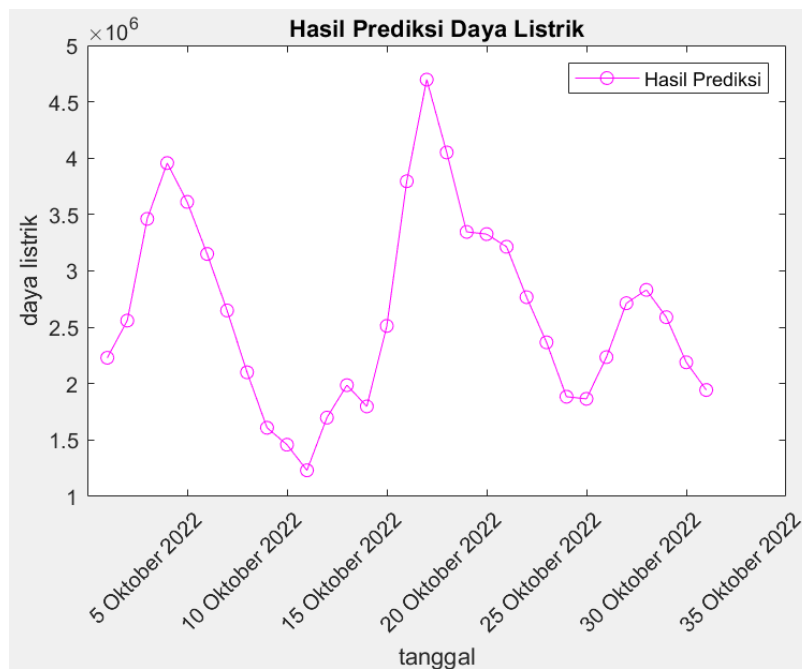
Setelah mendapatkan hasil prediksi, langkah selanjutnya adalah melakukan denormalisasi terhadap data. Denormalisasi data dilakukan untuk mengembalikan data ke dalam rentang nilai aslinya setelah diproses oleh model [35]. Hasil dari data yang telah didenormalisasi digunakan untuk menghitung prediksi besar daya listrik tiga puluh satu hari kedepan menggunakan PLTGL-OWC dengan Persamaan (1). Hasil prediksi besar daya listrik tiga puluh satu hari kedepan ditunjukkan pada Gambar 7.



Gambar 5 Grafik hasil prediksi parameter panjang



Gambar 6 Grafik hasil prediksi parameter periode



Gambar 7 Grafik hasil prediksi besar daya listrik (watt)

Gambar 7 merupakan representasi visual dari hasil prediksi daya listrik di Laut Sawu. Prediksi ini diperoleh melalui perhitungan menggunakan Persamaan (1) dengan mengumpamakan *chamber* pada PLTGL-OWC memiliki luas 35 m^2 . Berdasarkan hasil prediksi daya listrik pada penelitian ini, rata-rata daya listrik yang dihasilkan pada 1 sampai 31 Oktober 2022 adalah 2.639.865,948 watt per hari dengan daya listrik terendah pada 11 Oktober 2022 dan daya listrik terbesar pada 17 Oktober 2022.

IV. SIMPULAN

Sistem prediksi daya listrik yang diterapkan menggunakan metode Bi-LSTM untuk pemanfaatan energi terbarukan di Laut Sawu dengan parameter tinggi gelombang h , panjang gelombang λ , dan periode gelombang T terbukti efektif sesuai dengan tujuannya. Dari beberapa kali uji coba, MAPE terendah parameter h , λ , dan T masing-masing 9,1943%, 11,3585%, dan 7,1485% diperoleh pada kombinasi *hyperparameter node hidden layer 5* dan *batch size 4*. Nilai MAPE tersebut menunjukkan bahwa Bi-LSTM baik untuk memprediksi daya listrik yang dihasilkan oleh PLTGL-OWC di Laut Sawu sesuai dengan tabel kriteria MAPE. Hasil prediksi besar daya listrik yang dihasilkan rata-rata adalah 2.639.865,948 watt per hari. Angka tersebut menunjukkan potensi besar PLTGL-OWC di Laut Sawu dapat menyumbangkan energi terbarukan bagi masyarakat daerah Nusa Tenggara Timur (NTT), serta berperan dalam meningkatkan rendahnya rasio elektrifikasi.

Tantangan teknis, ekonomi, sosial, dan regulasi masih menjadi hambatan yang perlu diatasi. Implikasi dari kondisi ini membuka peluang penelitian lebih lanjut, khususnya dalam pengembangan teknologi PLTGL-OWC yang lebih efisien dan tahan terhadap lingkungan laut. Selain itu, penelitian kebijakan juga diperlukan untuk merumuskan regulasi yang adaptif, mendorong investasi, serta menjamin keberlanjutan program elektrifikasi nasional. Dengan demikian, PLTGL-OWC di Laut Sawu tidak hanya relevan sebagai solusi energi masa kini, tetapi juga sebagai agenda strategis penelitian dan inovasi di masa depan.

DAFTAR REFERENSI

- [1] M. Widyartono and R. Rahmadian, "OTEC potential of East Nusa Tenggara Province in Indonesia," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 336, no. 1, pp. 1–7, 2018, doi: 10.1088/1757-899X/336/1/012005.
- [2] Kementerian Energi dan Sumber Daya Mineral, Direktorat Jenderal Ketenagalistrikan, *Statistik Ketenagalistrikan Tahun 2020*, 34th ed. Jakarta: Sekretariat Direktorat Jenderal Ketenagalistrikan, 2021.
- [3] M. T. Sambodo, A. H. Fuady, S. D. Negara, F. W. Handoyo, and E. Mychelidisa, *Electricity Access and Community Welfare in Indonesia*. Jakarta, 2021, doi: 10.1007/978-981-16-3611-0.
- [4] J. U. Jasron, D. P. Mangesa, K. Boimau, B. V. Tarigan, E. U. K. Maliwemu, and M. Salombe, "Analisa potensi gelombang laut sebagai sumber energi terbarukan menggunakan perangkat oscillating water column (OWC) di wilayah perairan Laut Timor," *LONTAR J. Tek. Mesin Undana*, vol. 9, no. 1, pp. 14–20, 2022, doi: 10.35508/ljtmu.v9i01.7269.
- [5] C. Olah, "Understanding LSTM networks," *Colah's Blog*, 2015. [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [6] Y. L. He, L. Chen, Y. Gao, J. H. Ma, Y. Xu, and Q. X. Zhu, "Novel double-layer bidirectional LSTM network with improved attention mechanism for predicting energy consumption," *ISA Trans.*, vol. 118, pp. 50–60, 2021.
- [7] A. H. Asyhar, A. Z. Foady, M. Thohir, A. Z. Arifin, D. Z. Haq, and D. C. R. Novitasari, "Implementation of LSTM algorithm for cervical cancer using colposcopy data," in *Proc. Int. Conf. Artif. Intell. Inf. Commun. (ICAIIIC)*, 2020, pp. 485–489, doi: 10.1109/ICAIIIC48513.2020.9065068.
- [8] M. W. P. Aldi, Jondri, and A. Aditsania, "Analisis dan implementasi long short term memory neural network untuk prediksi harga Bitcoin," *e-Proceeding Eng.*, vol. 5, no. 2, pp. 3548–3555, 2018.
- [9] M. Hammad, M. Shoaib, H. Salahudin, M. A. I. Baig, M. M. Khan, and M. K. Ullah, "Rainfall forecasting in Upper Indus Basin using various artificial intelligence techniques," *Stoch. Environ. Res. Risk Assess.*, vol. 35, no. 1–2, pp. 1–23, 2021, doi: 10.1007/s00477-021-02013-0.
- [10] B. Y. Phiadelvira, D. Z. Haq, D. C. R. Novitasari, and F. Setiawan, "Prediksi besar daya listrik tenaga gelombang laut metode oscillating water column (PLTGL-OWC) di Banyuwangi menggunakan extreme learning machine (ELM)," *Unnes J. Math.*, vol. 11, no. 1, pp. 1–7, 2022, doi: 10.15294/ujm.v11i1.50967.
- [11] Y. Huérfano-Maldonado, M. Mora, K. Vilches, R. Hernández-García, R. Gutiérrez, and M. Vera, "A comprehensive review of extreme learning machine on medical imaging," *Neurocomputing*, vol. 556, pp. 1–20, 2023, doi: 10.1016/j.neucom.2023.126618.
- [12] A. Goudjil, M. K. Smail, and M. Nahas, "An end-to-end approach based on a bidirectional long short-term memory neural network for diagnosing wiring networks using reflectometry," *Sustainability*, vol. 17, no. 14, pp. 1–20, 2025, doi: 10.3390/su17146241.
- [13] S. P. Safda, M. M. Danial, and A. D. Lestari, "Gelombang laut sebagai energi alternatif pembangkit listrik tenaga gelombang laut di perairan Pantai Utara Kabupaten Sambas Kalimantan Barat," *JeLAST J. Tek. Kelautan, PWK, Sipil*,

- dan Tambang*, vol. 11, no. 1, pp. 1–8, 2024.
- [14] K. Huang and S. Pu, “CEDAS: A compressed decentralized stochastic gradient method with improved convergence,” *IEEE Trans. Automat. Contr.*, vol. 70, no. 4, pp. 2242–2257, 2024, doi: 10.1109/TAC.2024.3471854.
- [15] R. L. Abduljabbar, H. Dia, and P. W. Tsai, “Development and evaluation of bidirectional LSTM freeway traffic forecasting models using simulation data,” *Sci. Rep.*, vol. 11, no. 1, pp. 1–16, 2021, doi: 10.1038/s41598-021-03282-z.
- [16] P. Serras, G. Ibarra-Berastegi, J. Sáenz, and A. Ulazia, “Combining random forests and physics-based models to forecast the electricity generated by ocean waves: A case study of the Mutriku wave farm,” *Ocean Eng.*, vol. 189, pp. 1–12, 2019, doi: 10.1016/j.oceaneng.2019.106314.
- [17] H. Tyrallis and G. Papacharalampous, “Variable selection in time series forecasting using random forests,” *Algorithms*, vol. 10, no. 4, pp. 1–20, 2017, doi: 10.3390/a10040114.
- [18] I. R. Siregar, A. Nugraha, K. A. Notodiputro, Y. Angraini, and L. N. A. Mualifah, “The comparison of long short-term memory and bidirectional long short-term memory for forecasting coal price,” *Barekeng*, vol. 19, no. 1, pp. 245–258, 2025, doi: 10.30598/barekengvol19iss1pp245-258.
- [19] I. P. B. Priadinata, I. G. I. Sudipa, N. P. S. Meinarni, I. M. L. Radhitya, and I. K. D. G. Supartha, “Comparative analysis of LSTM, GRU, and Bi-LSTM deep learning models for time series cryptocurrency price forecasting,” *Sink. J. Penelit. Tek. Inform.*, vol. 9, no. 3, pp. 1024–1035, 2025, doi: 10.33395/sinkron.v9i3.14795.
- [20] S. Arrohan and D. A. Himawanto, “Peluang dan tantangan pengembangan teknologi oscilating water column (OWS) di Indonesia,” *J. Energi dan Teknol. Manufaktur*, vol. 4, no. 1, pp. 37–42, 2021, doi: 10.33795/jetm.v4i01.24.
- [21] L. N. N. Afifah and I. T. Safira, “Optimalisasi desain turbin Wells pada sistem osilasi kolom air pembangkit listrik tenaga gelombang laut sebagai upaya meningkatkan potensi supply energi terbarukan pada masyarakat pesisir,” *J. Offshore Oil, Prod. Facil. Renew. Energy*, vol. 4, no. 2, pp. 26–37, 2020, doi: 10.30588/jo.v4i2.831.
- [22] I. W. A. Wijaya, “Pembangkit listrik tenaga gelombang laut menggunakan teknologi oscilating water column di perairan Bali,” *Teknol. Elektro*, vol. 9, no. 2, pp. 165–174, 2010.
- [23] L. Wei, L. Guan, and L. Qu, “Prediction of sea surface temperature in the South China Sea by artificial neural networks,” *IEEE Geosci. Remote Sens. Lett.*, vol. 16, no. 12, pp. 1–5, 2019.
- [24] D. D. Pramesti, D. C. R. Novitasari, F. Setiawan, and H. Khaulasari, “Prediction of sea surface current velocity and direction in Bali Strait using long short-term memory (LSTM),” *Barekeng J. Ilmu Mat. dan Terap.*, vol. 16, no. 1, pp. 49–57, 2022, doi: 10.30598/barekengvol16iss2pp451-462.
- [25] D. Z. Haq et al., “Long short-term memory algorithm for rainfall prediction based on El-Nino and IOD data,” *Procedia Comput. Sci.*, vol. 179, pp. 829–837, 2021, doi: 10.1016/j.procs.2021.01.071.
- [26] I. I. Zulfa, D. C. R. Novitasari, F. Setiawan, A. Fanani, and M. Hafiyusholeh, “Prediction of sea surface current velocity and direction using LSTM,” *Indones. J. Electron. Instrum. Syst. (IJEIS)*, vol. 11, no. 1, pp. 93–100, 2021, doi: 10.1016/j.procs.2021.01.071.
- [27] G. Xu, Y. Meng, X. Qiu, Z. Yu, and X. Wu, “Sentiment analysis of comment texts based on BiLSTM,” *IEEE Access*, vol. 7, pp. 1–11, 2019, doi: 10.1109/ACCESS.2019.2909919.
- [28] M. Maimaiti, A. Wumaier, K. Abiderexiti, and T. Yibulayin, “Bidirectional long short-term memory network with a conditional random field layer for Uyghur part-of-speech tagging,” *Inf.*, vol. 8, no. 4, pp. 1–12, 2017, doi: 10.3390/info8040157.
- [29] J. Kim and N. Moon, “BiLSTM model based on multivariate time series data in multiple field for forecasting trading area,” *J. Ambient Intell. Humaniz. Comput.*, vol. 11, no. 7, pp. 2805–2814, 2019, doi: 10.1007/s12652-019-01398-9.
- [30] S. Prayudani, A. Hizriadi, Y. Y. Lase, Y. Fatmi, and Al-Khowarizmi, “Analysis accuracy of forecasting measurement technique on random k-nearest neighbor (RKNN) using MAPE and MSE,” *J. Phys. Conf. Ser.*, vol. 1361, no. 1, pp. 1–8, 2019, doi: 10.1088/1742-6596/1361/1/012089.
- [31] Y. Sun, F. Haghighat, and B. C. M. Fung, “A review of the state-of-the-art in data-driven approaches for building energy prediction,” *Energy Build.*, vol. 221, p. 110022, 2020, doi: 10.1016/j.enbuild.2020.110022.
- [32] A. N. Rais, R. Rousyati, I. J. Thira, D. N. Kholifah, N. Purwati, and Y. M. Kristania, “Evaluasi metode forecasting pada data kunjungan wisatawan mancanegara ke Indonesia,” *Evolusi J. Sains dan Manaj.*, vol. 8, no. 2, pp. 104–115, 2020, doi: 10.31294/evolusi.v8i2.8971.
- [33] T. Moon, S. Hong, H. Y. Choi, D. H. Jung, S. H. Chang, and J. E. Son, “Interpolation of greenhouse environment data using multilayer perceptron,” *Comput. Electron. Agric.*, vol. 166, pp. 1–8, 2019, doi: 10.1016/j.compag.2019.105023.
- [34] D. I. Puteri, “Implementasi long short term memory (LSTM) dan bidirectional long short term memory (BiLSTM) dalam prediksi harga saham syariah,” *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 11, no. 1, pp. 35–43, 2023, doi: 10.34312/euler.v11i1.19791.
- [35] A. Giusti, A. W. Widodo, and S. Adinugroho, “Prediksi penjualan mi menggunakan metode extreme learning machine (ELM) di Kober Mie Setan cabang Soekarno Hatta,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 8, pp. 2972–2978, 2018.
- [36] J. Reynaldo, P. P. Adikara, and R. C. Wihandika, “Analisis sentimen mengenai produk Toyota Avanza menggunakan

- metode learning vector quantization versi 3 (LVQ 3) dengan seleksi fitur Chi Square, lexicon-based features serta normalisasi min-max,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 4, no. 3, pp. 830–839, 2020.
- [37] Musfiroh, D. C. R. Novitasari, P. K. Intan, and G. G. Wisnawa, “Penerapan metode principal component analysis (PCA) dan long short-term memory (LSTM) dalam memprediksi curah hujan harian,” *Build. Informatics, Technol. Sci.*, vol. 5, no. 1, pp. 1–11, 2023, doi: 10.47065/bits.v5i1.3114.
- [38] J. Leites, V. Cerqueira, and C. Soares, “Lag selection for univariate time series forecasting using deep learning: An empirical study,” *arXiv preprint arXiv:2405.11237*, 2024, doi: 10.1007/978-3-031-73503-5_26.
- [39] H. Siqueira et al., “Selection of temporal lags for predicting riverflow series from hydroelectric plants using variable selection methods,” *Energies*, vol. 13, no. 6, pp. 1–20, 2020, doi: 10.3390/en13164236.
- [40] M. Gauch, F. Kratzert, D. Klotz, G. Nearing, J. Lin, and S. Hochreiter, “Rainfall-runoff prediction at multiple timescales with a single long short-term memory network,” *Hydrol. Earth Syst. Sci.*, vol. 25, no. 4, pp. 2045–2062, 2021, doi: 10.5194/hess-25-2045-2021.
- [41] Y. Xiao, H. Yin, Y. Zhang, H. Qi, Y. Zhang, and Z. Liu, “A dual-stage attention-based Conv-LSTM network for spatio-temporal correlation and multivariate time series prediction,” *Int. J. Intell. Syst.*, vol. 36, no. 5, pp. 2036–2057, 2021, doi: 10.1002/int.22370.
- [42] D. Tomar, P. Tomar, A. Bhardwaj, and G. R. Sinha, “Deep learning neural network prediction system enhanced with best window size in sliding window algorithm for predicting domestic power consumption in a residential building,” *Comput. Intell. Neurosci.*, 2022, doi: 10.1155/2022/7216959.
- [43] Y. Syukriyah and A. Purnama, “Modelling time series data for stock prices prediction using bidirectional long short-term memory,” *Knowbase Int. J. Knowl. Database*, vol. 4, no. 2, pp. 115–129, 2024.
- [44] E. Seidi, F. Kaviari, and S. F. Miller, “Hyperparameter tuning of artificial neural network-based machine learning to optimize number of hidden layers and neurons in metal forming,” *J. Manuf. Mater. Process.*, vol. 9, no. 8, p. 260, 2025, doi: 10.3390/jmmp9080260.
- [45] A. Q. Khan, H. A. Awan, M. Rasul, Z. A. Siddiqi, and A. Pimanmas, “Optimized artificial neural network model for accurate prediction of compressive strength of normal and high strength concrete,” *Clean. Mater.*, vol. 10, p. 100211, 2023, doi: 10.1016/j.clema.2023.100211.
- [46] A. M. Rather, “LSTM-based deep learning model for stock prediction and predictive optimization model,” *EURO J. Decis. Process.*, vol. 9, p. 100001, 2021, doi: 0.1016/j.ejdp.2021.100001.
- [47] T. I. Z. M. Putra, Suprpto, and A. F. Bukhori, “Model klasifikasi berbasis multiclass classification dengan kombinasi Indobert embedding dan long short-term memory untuk tweet berbahasa Indonesia,” *J. Ilmu Siber dan Teknol. Digit.*, vol. 1, no. 1, pp. 1–28, 2022, doi: 10.35912/jisted.v1i1.1509.
- [48] D. Masters and C. Luschi, “Revisiting small batch training for deep neural networks,” *arXiv preprint arXiv:1804.07612*, 2018.
- [49] J. S. Hwang, S. S. Lee, J. W. Gil, and C. K. Lee, “Determination of optimal batch size of deep learning models with time series data,” *Sustainability*, vol. 16, no. 14, pp. 1–11, 2024, doi: 10.3390/su16145936.

Icha Dwi Safira, telah menyelesaikan pendidikan S1 Matematika di Universitas Islam Negeri Sunan Ampel Surabaya. Saat ini sedang melanjutkan studi S2 Manajemen di Universitas Ciputra Surabaya.

Dian Candra Rini Novitasari, telah menyelesaikan pendidikan S3 Matematika dan Ilmu Pengetahuan Alam di Universitas Airlangga Surabaya. Saat ini aktif sebagai dosen di Program Studi Matematika UIN Sunan Ampel Surabaya.

Nurissaidah Ulinnuha, telah menyelesaikan pendidikan S2 Teknik Informatika di Institut Teknologi Sepuluh Nopember. Saat ini aktif sebagai dosen di Program Studi Matematika UIN Sunan Ampel Surabaya.

Fajar Setiawan, berprofesi sebagai forecaster di Stasiun Meteorologi Maritim Perak II Surabaya.