

SEA LEVEL PREDICTION USING GATED RECURRENT UNIT AND BIDIRECTIONAL LONG SHORT-TERM MEMORY METHODS

PREDIKSI TINGGI MUKA AIR LAUT MENGGUNAKAN METODE *GATED RECURRENT UNIT* DAN *BIDIRECTIONAL LONG SHORT-TERM MEMORY*

Anting B.N Sinurat¹, Wildan Aprizal Arifin², Wenny Ananda Larasati³

^{1,2}Universitas Pendidikan Indonesia,

Jl. Dr. Setiabudi No. 229, Isola, Kec. Sukasari, Kota Bandung, Jawa Barat, Indonesia

E-mail: wildanarifin@upi.edu

Abstract - Coastal areas are areas that border between land and sea. One of the main threats to this area is flooding due to rising sea levels. The coastal areas in the South Lampung Waters are geographically located directly opposite the Sunda Strait. In this area, there are various economic activities of the community and settlements that are greatly influenced by sea dynamics, including tides. This study aims to predict sea level in the South Lampung Waters using the GRU method and compare the prediction results of the model with the BiLSTM model. This study involves steps such as data collection, data pre-processing, model training, modeling, evaluation and analysis. The data used is sea level data for one year, from June 1, 2023 to May 31, 2024, which is divided into training data (80%) and test data (20%). Evaluation of the test results and predictions of the two models is carried out using MAE and RMSE. The results of the research that has been carried out, the BiLSTM method is superior to the GRU method in predicting water levels. This can be seen from the MAE and RMSE values obtained, where the BiLSTM method has the lowest MAE value of 0.0102 and RMSE of 0.0218, while the GRU method has a MAE value of 0.0164 and RMSE of 0.0277. So in this study it can be concluded that the BiLSTM method is more accurate and effective than the GRU method in predicting sea level in the South Lampung Waters.

Keywords - BILSTM, GRU, sea level rise.

Intisari - Wilayah pesisir merupakan area yang berbatasan antara daratan dan laut. Salah satu ancaman utama bagi kawasan ini adalah banjir akibat peningkatan permukaan air laut. Wilayah pesisir di Perairan Lampung Selatan secara geografis terletak berhadapan langsung dengan Selat Sunda. Di kawasan ini, terdapat berbagai aktivitas ekonomi masyarakat dan pemukiman yang sangat dipengaruhi oleh dinamika laut, termasuk pasang surut. Penelitian ini bertujuan untuk melakukan prediksi tinggi muka air laut di Perairan Lampung Selatan menggunakan metode GRU serta membandingkan hasil prediksi pada model tersebut dengan model BiLSTM. Penelitian ini melibatkan langkah-langkah seperti pengumpulan data, *pre-processing data*, *training* model, pemodelan, evaluasi dan analisis. Data yang digunakan adalah data muka air laut selama satu tahun, dari 1 Juni 2023 hingga 31 Mei 2024, yang dibagi menjadi data latih (80%) dan data uji (20%). Evaluasi hasil uji dan prediksi kedua model dilakukan menggunakan MAE dan RMSE. Hasil penelitian yang telah dilakukan, metode BiLSTM lebih unggul dibandingkan dengan metode GRU dalam memprediksi tinggi muka air. Hal ini terlihat dari nilai MAE dan RMSE yang diperoleh, di mana metode BiLSTM memiliki nilai MAE terendah sebesar 0.0102 dan RMSE 0.0218, sementara metode GRU memiliki nilai MAE 0.0164 dan RMSE 0.0277. Sehingga pada penelitian ini dapat disimpulkan bahwa metode BiLSTM lebih akurat dan efektif dibandingkan dengan metode GRU dalam memprediksi tinggi muka air laut pada Perairan Lampung Selatan.

Kata Kunci - BILSTM, GRU, kenaikan permukaan laut.

I. PENDAHULUAN

Wilayah pesisir merupakan area yang berbatasan antara daratan dan laut. Salah satu ancaman utama bagi kawasan ini adalah banjir akibat peningkatan permukaan air laut. Peningkatan tersebut memberikan dampak besar terhadap lingkungan serta infrastruktur di daerah pesisir. Dataran rendah di pesisir menjadi wilayah yang paling rentan terhadap ancaman ini. Proyeksi kenaikan permukaan laut di masa depan menunjukkan bahwa banyak kota mungkin akan tenggelam [1]. Pemanasan global, yang menyebabkan pencairan es di kutub dan gletser, serta ekspansi volume air laut, memicu fenomena ini [2]. Selain itu, aktivitas tektonik dan vulkanik juga bisa menyebabkan kenaikan permukaan laut [3]. Pertumbuhan pesisir yang pesat, termasuk peningkatan jumlah penduduk dan perkembangan ekonomi yang intensif, serta infrastruktur yang penting, menjadikan kenaikan permukaan laut sebagai ancaman serius yang patut diwaspadai. Dampaknya bervariasi tergantung pada lokasi, karakteristik fisik, kondisi sosial ekonomi, serta respon masyarakat yang tinggal di wilayah tersebut [4]. Wilayah pesisir di Perairan Lampung Selatan secara geografis terletak berhadapan langsung dengan Selat Sunda. Di kawasan ini, terdapat berbagai aktivitas ekonomi masyarakat dan pemukiman yang sangat dipengaruhi oleh dinamika laut, termasuk pasang surut. Sebagai area strategis dengan potensi yang besar, pesisir ini memberikan manfaat yang signifikan bagi penduduk setempat. Potensi seperti pelabuhan, pemukiman, pertanian, tambak, serta pariwisata yang ada di wilayah pesisir Lampung Selatan akan sangat merugikan jika terganggu oleh bencana seperti banjir rob.

Di tengah tantangan tersebut, Sistem Informasi Kelautan sebuah cabang dari Ilmu Kelautan memiliki peran krusial dalam menganalisis data kelautan secara numerik dan spasial. Sistem ini dirancang untuk mendukung pengambilan keputusan yang tepat dalam menghadapi kompleksitas tantangan di era Revolusi Industri 4.0, khususnya di sektor kelautan [5]. Oleh karena itu, perlu dilakukan prediksi terhadap kenaikan muka air laut agar dapat dijadikan acuan dalam penanganan bencana. *Machine Learning* merupakan salah satu bidang yang paling signifikan dalam prediksi [6]. Penggunaan metode komputasi dan algoritma matematika dengan penekanan pada analisis data untuk memperkirakan kejadian di masa depan dikenal sebagai *machine learning*. Tujuan utama dari *Machine Learning* adalah mengembangkan sistem yang dapat belajar dan mengambil keputusan secara mandiri, tanpa memerlukan modifikasi atau intervensi dari manusia. Selain mampu menetapkan pedoman untuk pengambilan keputusan, sistem ini juga dapat menyesuaikan diri dengan perubahan di lingkungan sekitarnya [7].

Machine Learning menawarkan berbagai metode dan algoritma untuk prediksi, termasuk *Gated Recurrent Unit* (GRU) dan *Bidirectional Long Short-Term Memory* (BiLSTM). GRU merupakan hasil pengembangan dari *Recurrent Neural Network* (RNN) yang sering digunakan dalam penelitian yang melibatkan pemrosesan data, video, dan data time series. Algoritma ini dirancang untuk mengatasi masalah ketergantungan jangka panjang yang sering terjadi pada RNN, sehingga meningkatkan efisiensi dalam analisis data [8]. Di sisi lain, BiLSTM adalah bentuk jaringan neural yang sangat efektif untuk memodelkan data time series, dengan arsitektur yang fleksibel dan dapat diadaptasi untuk berbagai keperluan aplikasi. Langkah-langkah utama dalam menggunakan BiLSTM meliputi mendefinisikan jaringan, mengkompilasi, melatih, mengevaluasi, serta membuat prediksi. Dengan menggunakan BiLSTM, prediksi dapat dilakukan secara lebih akurat dengan memperhitungkan data masukan yang relevan [9]. GRU dan BiLSTM telah banyak digunakan untuk prediksi. Dalam penelitian yang dilakukan oleh Alghifari et al [10], BiLSTM terbukti lebih efektif untuk analisis sentimen layanan Grab Indonesia, dengan akurasi mencapai 91% dan training loss sebesar 28%. Sementara itu, Rizky [11] melakukan perbandingan antara LSTM dan BiLSTM untuk klasifikasi sinyal jantung dari phonocardiogram. Hasilnya menunjukkan bahwa BiLSTM

menghasilkan rata-rata precision 86%, recall 85%, specificity 87%, dan F1-Score 85%, sedangkan LSTM menghasilkan precision 83%, recall 67%, specificity 86%, dan F1-Score 73%. Akurasi tertinggi yang diperoleh LSTM adalah 81%, sedangkan BiLSTM mencapai 89%. Dalam studi lain, Agusmawati et al [12] mempelajari prediksi harga emas menggunakan LSTM dan GRU, dan menemukan bahwa GRU lebih baik dalam hal akurasi dibandingkan LSTM. GRU mencatat MAE sebesar 0,0447, RMSE 0,0545, dan MAPE 6,0688%, sementara model LSTM terbaik mencatat MAE 0,0389, RMSE 0,0475, dan MAPE 5,2047%. Berdasarkan penelitian ini, GRU menunjukkan performa yang lebih unggul dibandingkan LSTM dalam memprediksi harga emas.

Berdasarkan identifikasi masalah dan beberapa temuan dari penelitian terdahulu, penelitian ini bertujuan untuk memprediksi tinggi muka air laut di Perairan Lampung Selatan menggunakan metode GRU serta membandingkan hasil prediksinya dengan model BiLSTM. Metode ini dipilih berdasarkan hasil dari kajian sebelumnya menunjukkan bahwa BiLSTM dan GRU merupakan model yang sangat baik untuk digunakan dalam prediksi.

II. SIGNIFIKANSI STUDI

A. *Studi Literatur*

Dalam penelitian ini, penulis mengumpulkan beberapa literatur yang berkaitan dengan topik yang diteliti. Adapun studi literatur yang dikaji adalah sebagai berikut:

1. *Machine Learning (ML)*

Machine Learning (ML) adalah bidang ilmu yang mengkhususkan diri dalam pengembangan dan analisis algoritma yang memungkinkan komputer mengekstrak pengetahuan dari data. Algoritma ML membantu melatih model yang dapat mengambil keputusan berdasarkan data yang tersedia [13]. Dengan ML, masalah diselesaikan dengan model yang secara akurat merepresentasikan data [14]. Selain itu, ML juga mengoptimalkan proses pengambilan keputusan dengan secara otomatis memberikan wawasan prediktif [15].

2. *Tinggi Muka Air Laut (Sea Level Rise)*

Kenaikan muka air laut merupakan fenomena alam yang disebabkan oleh peningkatan volume air laut secara signifikan. Peningkatan ini terutama disebabkan oleh pemanasan global, yang berdampak pada perubahan iklim global dan menyebabkan mencairnya es di kutub, sehingga menambah volume air di lautan. Jika suhu bumi terus meningkat maka proses pencairan gletser akan semakin cepat sehingga memperburuk keadaan saat ini. Tren kenaikan permukaan air laut secara global menunjukkan tren yang mengkhawatirkan, meningkat dari 3,2 mm per tahun antara 1993-2015 menjadi 3,6 mm per tahun antara 2006-2015, berdasarkan laporan *Intergovernmental Panel on Climate Change* (IPCC) tahun 2021 [16]. Kenaikan muka air laut yang terus menerus dapat menyebabkan terjadinya banjir pasang (rob), di mana air laut dapat memasuki daratan dan menggenangi wilayah pesisir, yang berpotensi merusak ekosistem dan infrastruktur serta mengancam kehidupan masyarakat di daerah tersebut [17].

3. *Prediksi*

Prediksi dapat diartikan sebagai peramalan atau perkiraan tentang suatu kejadian yang akan datang. Dalam konteks yang lebih spesifik, prediksi merujuk pada hasil dari suatu proses analisis data untuk memperkirakan nilai atau kejadian di masa depan. Menurut KBBI, prediksi adalah hasil dari kegiatan memperkirakan atau meramalkan berdasarkan informasi atau data historis yang telah terjadi di masa lalu. Proses ini melibatkan analisis dan interpretasi data

sebelumnya untuk menghasilkan gambaran mengenai apa yang mungkin terjadi di waktu yang akan datang [18].

4. *Bidirectional Bidirectional Long Short-Term Memory*

BiLSTM merupakan sebuah inovasi yang dikembangkan dari model LSTM untuk meningkatkan kemampuannya dalam menangani data berurutan. Model BiLSTM terdiri dari dua lapisan jaringan LSTM yang beroperasi berlawanan arah, yaitu lapisan LSTM forward dan lapisan LSTM backward. Lapisan forward dirancang untuk memproses urutan data mulai dari awal hingga akhir, sehingga dapat menangkap informasi kontekstual yang muncul dalam urutan tersebut. Di sisi lain, lapisan backward bertugas untuk memproses urutan data dari akhir menuju awal, memungkinkan model untuk mempertimbangkan konteks yang ada sebelum titik tertentu dalam urutan. Gabungan dari kedua lapisan ini dalam setiap langkah waktu memberikan model kemampuan yang lebih baik untuk memahami hubungan dan pola dalam data, sehingga meningkatkan akurasi prediksi dan efektivitas dalam berbagai aplikasi, seperti pengenalan suara, analisis teks, dan prediksi deret waktu [19].

5. *Gated Recurrent Unit*

GRU adalah sebuah model yang merupakan hasil modifikasi dari RNN yang lebih tradisional [20]. Salah satu keunggulan utama dari GRU adalah bahwa proses komputasinya dirancang lebih sederhana jika dibandingkan dengan LSTM, yang merupakan salah satu model RNN lainnya. Meskipun memiliki struktur yang lebih sederhana, GRU tetap mampu memberikan tingkat akurasi yang setara dengan LSTM dalam banyak aplikasi. Selain itu, GRU juga cukup efektif dalam mengatasi masalah hilangnya gradien (*vanishing gradient*), yang sering menjadi tantangan dalam pelatihan model RNN tradisional. Dengan kata lain, GRU menawarkan solusi yang lebih efisien tanpa mengorbankan performa, sehingga banyak digunakan dalam berbagai tugas yang melibatkan pengolahan urutan data [21].

6. *Mean Absolute Error (MAE)*

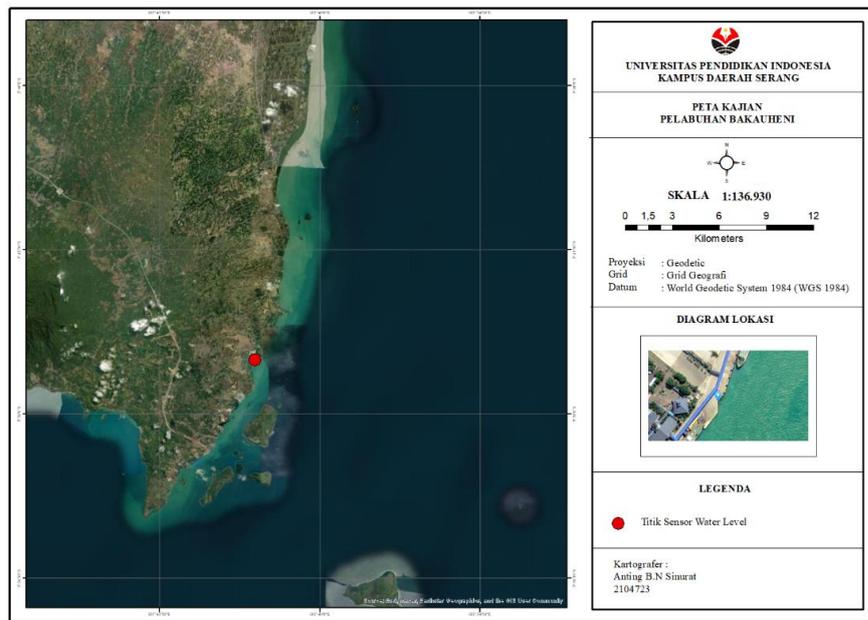
MAE merupakan metode yang sering digunakan untuk mengukur keakuratan model prediksi [22]. MAE dihitung dengan menjumlahkan semua selisih absolut antara hasil prediksi dan nilai aktual, lalu membaginya dengan jumlah data yang tersedia. Sederhananya, MAE menunjukkan kesalahan absolut rata-rata, yang menunjukkan seberapa besar penyimpangan perkiraan dari nilai sebenarnya, tanpa memperhatikan apakah prediksi tersebut lebih tinggi atau lebih rendah [23].

7. *Root Mean Squared Error (RMSE)*

RMSE adalah ukuran yang digunakan untuk menilai seberapa baik model dalam menghasilkan prediksi. RMSE dihitung dengan cara menghitung selisih antara nilai aktual dan prediksi, mengkuadratkan selisih tersebut, menjumlahkan semua nilai kuadrat, dan membagi hasilnya dengan jumlah total data. Setelah itu, akar kuadrat dari hasil pembagian diambil untuk memperoleh nilai RMSE. Nilai RMSE yang lebih rendah menunjukkan bahwa prediksi model lebih mendekati nilai sebenarnya, menandakan akurasi yang lebih tinggi. Sebaliknya, semakin tinggi nilai RMSE, semakin besar kesalahan prediksi, yang berarti akurasi model semakin rendah. RMSE memberikan ukuran yang jelas dan intuitif tentang performa model serta memungkinkan perbandingan yang lebih objektif antar model yang berbeda [24].

B. *Lokasi Studi Penelitian*

Lokasi studi pada penelitian ini dapat dilihat pada Gambar 1.

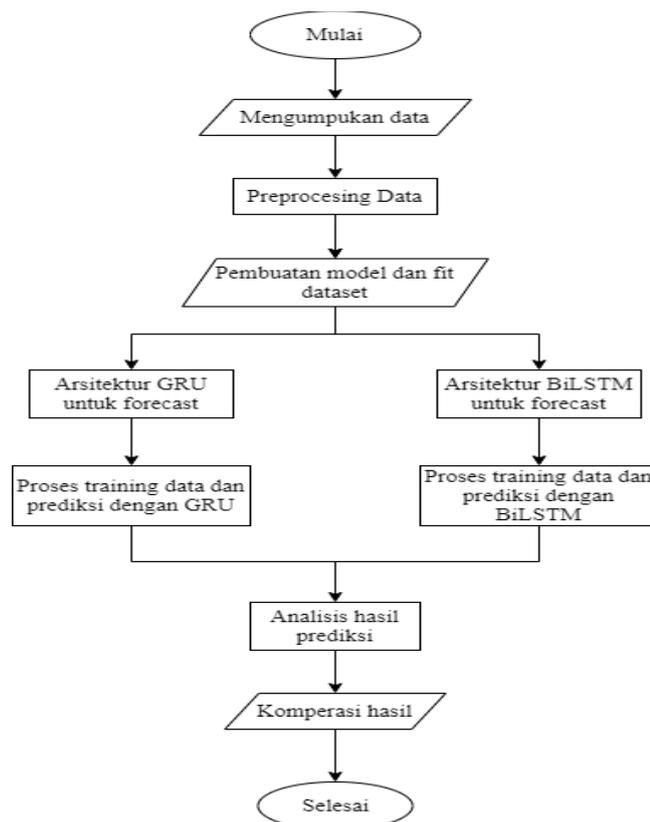


Gambar 1. Titik lokasi alat sensor waterlevel

Lokasi studi dalam penelitian ini berada di perairan Bakauheni, Lampung Selatan, seperti yang ditunjukkan pada Gambar 1. Data mengenai tinggi muka air laut diperoleh dari Stasiun Meteorologi Maritim Kelas IV Panjang, Lampung, dengan titik pengukuran yang ditandai oleh sensor waterlevel di lokasi tersebut.

C. Metode Penelitian

Pada bagian ini dijelaskan alur sistem yang dibangun dalam penelitian ini. Gambaran umum perancangan sistem pada penelitian ini ditunjukkan pada Gambar 2.

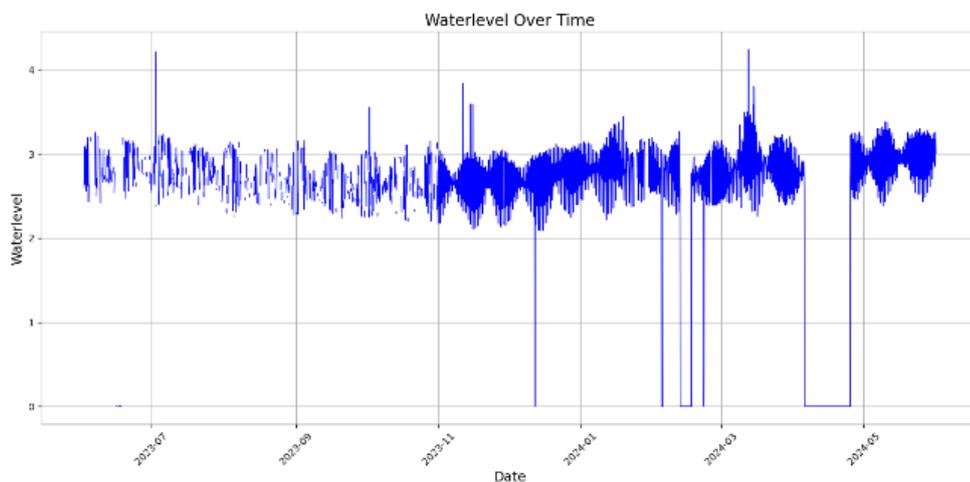


Gambar 2. Diagram alur penelitian

Langkah pertama yang dilakukan dalam penelitian ini adalah penyusunan data muka air laut. Data ini akan melalui tahap preprocessing untuk dua model yang diimplementasikan. Model yang digunakan ada dua, yaitu GRU dan BiLSTM. Setelah menyusun model GRU dan BiLSTM, pada tahap selanjutnya model tersebut akan melatih data yang masing-masing menghasilkan prediksi peramalan permukaan laut. Hasil yang diperoleh kemudian dibandingkan secara kualitatif dan kuantitatif dengan menggunakan MAE dan RMSE.

1. Pengumpulan Data

Pengumpulan data yang dilakukan pada penelitian ini yaitu dengan mengunduh data langsung dari situs web AWS BMKG Maritim Lampung. Banyak komponen yang tersedia dalam dataset ini seperti Waktu, *Windspeed*, *Winddir*, *Temp*, *Rh*, *Pressure*, *Rain*, *Solrad*, *Netrad*, *Watertemp* dan *Waterlevel*. Untuk penelitian ini komponen yang digunakan adalah *Waterlevel* (m) yang merupakan presentasi tinggi rendahnya permukaan laut.

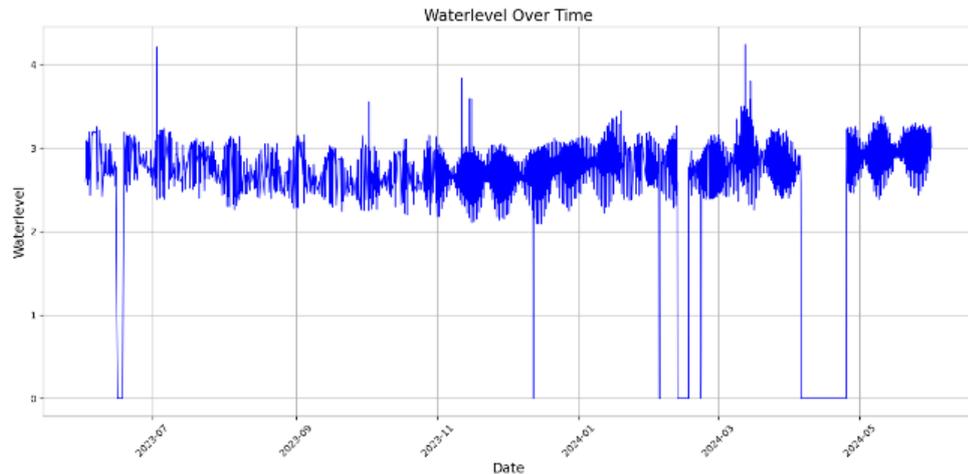


Gambar 3. Deret waktu data tinggi muka air laut

Gambar 3 menunjukkan data tinggi muka air laut air laut selama satu tahun, yaitu tanggal 1 Juni 2023 – 31 Mei 2024. Dataset yang diambil untuk penelitian kali ini adalah sebanyak 354.132 data tiap satuan waktu (menit). Untuk prediksi tinggi muka air laut ini, penulis melakukan resample dataset menjadi data per jam seperti yang ditunjukkan oleh Gambar 3. Akan tetapi, setelah proses resample dataset terdapat missing value dikarenakan data tidak terekam pada waktu tertentu.

2. Pre-processing Data

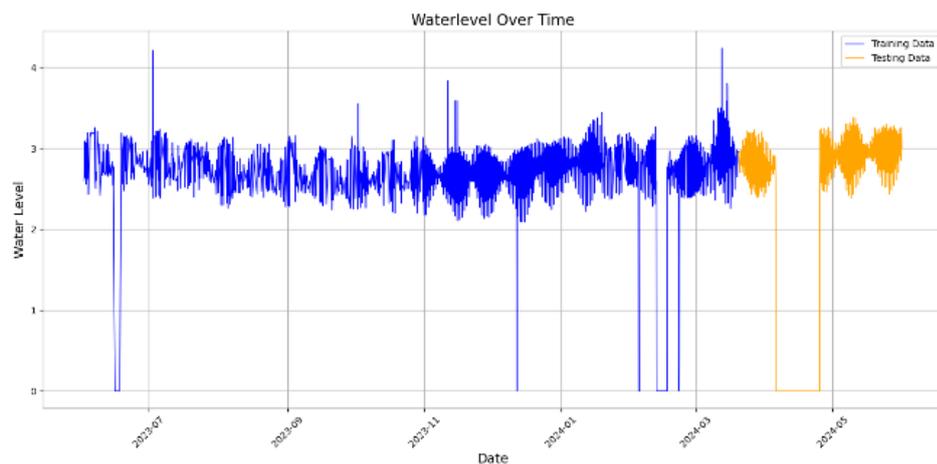
Pada tahap preprocessing, dataset tinggi muka air laut awalnya diukur setiap menit. Mengingat bahwa pengolahan data dengan frekuensi pengukuran yang sangat tinggi ini memerlukan waktu dan sumber daya komputasi yang cukup besar, dilakukan langkah resampling data untuk setiap interval satu jam. Proses resampling ini bertujuan untuk menyederhanakan data sekaligus mengurangi beban komputasi.



Gambar 4. Deret waktu data tinggi muka air laut dengan interpolasi

Setelah proses resampling, terdapat 2.307 data yang hilang. Oleh karena itu, dilakukan proses interpolasi untuk mengisi kekosongan tersebut. Proses interpolasi ini diperlukan karena adanya celah data yang kosong dengan rentang waktu yang cukup panjang, seperti yang ditunjukkan pada Gambar 4.

Kemudian setelah proses pengisian data yang hilang, dataset dibagi menjadi dua bagian yaitu data latih (*data train*) dan data uji (*data test*) dengan persentase 80% untuk data latih dan 20% untuk data uji. Pembagian dataset dilakukan berdasarkan urutan waktu, sehingga data pelatihan terdiri dari data pada periode awal, sementara data pengujian terdiri dari data yang diambil setelahnya.



Gambar 5. Pembagian data latih dan uji berdasarkan urutan waktu

Dari total 8.755 data yang tersedia, pembagian ini menghasilkan 7.004 data yang dialokasikan untuk data latih dan 1.751 data untuk data uji. Seperti yang ditunjukkan oleh gambar 5.

3. *Pemodelan GRU dan BiLSTM*

Dalam pelatihan dan pengujian model GRU dan BiLSTM, penting untuk melakukan penyesuaian parameter (*parameter tuning*) agar mendapatkan parameter yang optimal untuk prediksi. Parameter yang ditentukan sebelum pelatihan model akan mempengaruhi kualitas hasil prediksi yang diperoleh. Beberapa parameter yang diterapkan dalam penelitian ini dapat dilihat pada Tabel I.

TABEL I
DESKRIPSI PARAMETER MODEL

Parameter	Value
Lookback	30, 60
Batch	16, 32
Epoch	50, 100, 150, 200

4. *Evaluasi Model*

Setelah proses pelatihan model selesai, langkah berikutnya adalah melakukan evaluasi model menggunakan metrik evaluasi seperti MAE dan RMSE. Hal ini bertujuan untuk menilai kinerja model dalam memprediksi data secara akurat.

III. HASIL DAN PEMBAHASAN

1. *Evaluasi Model*

Berikut merupakan hasil evaluasi prediksi tinggi muka air laut menggunakan metrik MAE dan RMSE pada metode GRU dan BiLSTM. Hasil pengujian untuk setiap kombinasi parameter dapat dilihat pada Tabel II.

TABEL II
HASIL PENGUJIAN MAE DAN RMSE METODE GRU DAN BiLSTM

Lockbook	Batch Size	Epoch	GRU		BiLSTM	
			MAE	RMSE	MAE	RMSE
30	16	50	0.0464	0.0753	0.0192	0.0311
30	16	100	0.0428	0.0695	0.0225	0.0351
30	16	150	0.0606	0.0953	0.0289	0.0436
30	16	200	0.0478	0.0803	0.0383	0.0577
30	32	50	0.0190	0.0319	0.0145	0.0244
30	32	100	0.0183	0.0311	0.0102	0.0218
30	32	150	0.0164	0.0277	0.0130	0.0234
30	32	200	0.0231	0.0382	0.0149	0.0241
60	16	50	0.0481	0.0770	0.0219	0.0337
60	16	100	0.0530	0.0775	0.0150	0.0284
60	16	150	0.0530	0.0830	0.0120	0.0258
60	16	200	0.0393	0.0544	0.0110	0.0254
60	32	50	0.0249	0.0396	0.0165	0.0257
60	32	100	0.0191	0.0319	0.0165	0.0266
60	32	150	0.0170	0.0289	0.0170	0.0274
60	32	200	0.0234	0.0390	0.0133	0.0241

2. *Analisis*

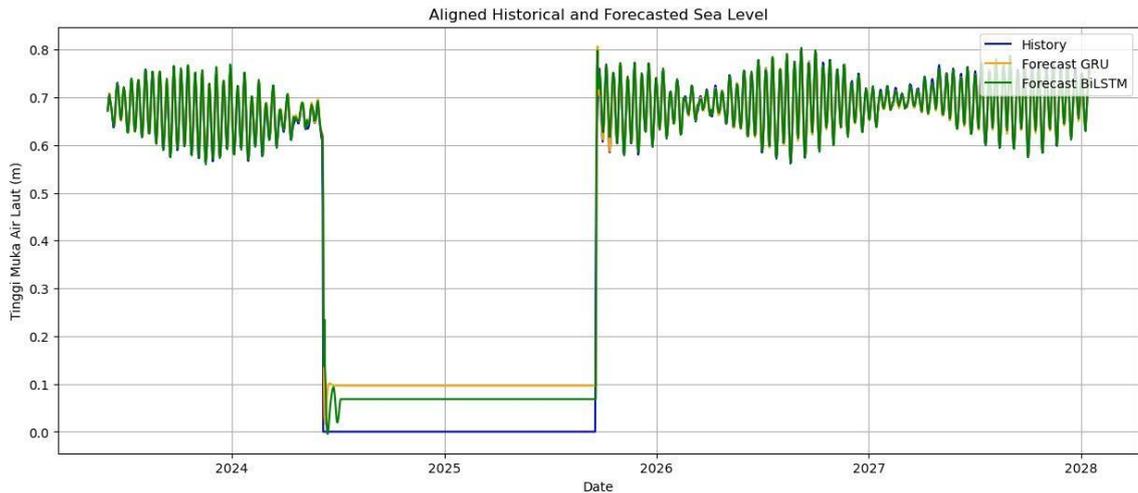
Berdasarkan Berdasarkan Tabel II, hasil pengujian MAE dan RMSE menunjukkan bahwa GRU dan BiLSTM adalah arsitektur jaringan saraf rekuren (RNN) yang dirancang untuk mengatasi masalah memori jangka panjang dalam pemodelan data berurutan. Penelitian ini membandingkan nilai MAE dan RMSE dari kedua metode tersebut dalam memprediksi tinggi muka air laut. Hasil pengujian menunjukkan bahwa BiLSTM memiliki nilai MAE dan RMSE yang lebih rendah, yaitu MAE 0.0102 dan RMSE 0.0218, sedangkan GRU memiliki MAE 0.0164 dan RMSE 0.0277. Ini mengindikasikan bahwa BiLSTM lebih unggul dibandingkan GRU dengan beberapa kombinasi parameter yang digunakan. Arsitektur BiLSTM yang lebih

sederhana memungkinkan model untuk lebih cepat mengenali pola selama proses training dengan dataset yang digunakan. Selain itu, hasil evaluasi menunjukkan bahwa nilai MAE dan RMSE pada metode GRU lebih bervariasi, dengan error yang kadang sangat tinggi atau sangat rendah, sedangkan pada BiLSTM nilainya lebih stabil dan konsisten.

Penelitian ini melibatkan beberapa kombinasi parameter, seperti Lockbook, batch size, dan epoch. Dari evaluasi nilai MAE dan RMSE dengan berbagai kombinasi parameter pada metode GRU dan BiLSTM, terlihat adanya perbedaan signifikan dalam performa kedua metode dalam memprediksi tinggi muka air laut. Hasilnya menunjukkan bahwa untuk metode GRU, kombinasi parameter terbaik adalah Lockbook 30, batch size 32, dan epoch 150, sementara pada BiLSTM, kombinasi optimal adalah Lockbook 30, batch size 32, dan epoch 100. Evaluasi tersebut juga menunjukkan bahwa penggunaan Lockbook 30 cenderung memberikan hasil yang lebih konsisten, dengan nilai MAE dan RMSE yang lebih rendah dibandingkan penggunaan Lockbook 60. Hal ini disebabkan oleh penurunan kompleksitas model, pencegahan overfitting, dan peningkatan efisiensi pembelajaran dengan Lockbook 30, yang memungkinkan model memberikan prediksi lebih akurat dibandingkan Lockbook 60, di mana model mungkin dipengaruhi oleh informasi yang tidak relevan.

Penggunaan batch size 16 dan 32 dalam kombinasi parameter tersebut juga berpengaruh pada nilai evaluasi MAE dan RMSE. Batch size 32 memberikan nilai evaluasi yang lebih rendah dibandingkan dengan batch size 16. Hal ini disebabkan karena dalam pembelajaran mesin, batch size mengacu pada jumlah sampel data yang digunakan dalam satu iterasi pelatihan model. Batch size yang lebih besar memerlukan lebih banyak memori, yang dapat mengakibatkan nilai MAE dan RMSE yang lebih tinggi jika sumber daya memori terbatas, seperti pada dataset yang digunakan dalam penelitian ini. Oleh karena itu, penggunaan batch size yang lebih kecil cenderung menghasilkan nilai MAE dan RMSE yang lebih rendah dibandingkan dengan penggunaan batch size yang lebih besar.

Dalam hal epoch, terdapat perbedaan performa antara GRU dan BiLSTM dengan kombinasi parameter yang berbeda serta jumlah epoch yang bervariasi. Pada beberapa kombinasi, peningkatan jumlah epoch dari 100 menjadi 150 menunjukkan peningkatan signifikan pada nilai MAE dan RMSE, yang menunjukkan bahwa model memperoleh keuntungan dari pelatihan yang lebih lama. Hal ini menunjukkan bahwa peningkatan jumlah epoch dapat meningkatkan kemampuan model untuk memahami pola data yang lebih kompleks. Berdasarkan Tabel II, hasil pengujian MAE dan RMSE menunjukkan bahwa untuk metode BiLSTM, kombinasi parameter terbaik yang digunakan adalah Lockbook 30, batch size 32, dan epoch 100, yang menghasilkan nilai MAE sebesar 0.0102 dan RMSE sebesar 0.0234. Di sisi lain, evaluasi metode GRU dengan kombinasi parameter terbaik, yaitu Lockbook 30, batch size 32, dan epoch 150, menghasilkan nilai MAE sebesar 0.0164 dan RMSE sebesar 0.0277. Perbandingan antara tinggi muka air laut yang sebenarnya dan hasil prediksi menggunakan metode GRU dan BiLSTM dengan parameter tersebut dapat dilihat pada Gambar 6.



Gambar 6. Hasil prediksi model GRU dan BiLSTM

Pada gambar 6. Hasil prediksi GRU dan BiLSTM dijelaskan bahwa garis biru menunjukkan data historis tinggi muka air laut yang digunakan sebagai referensi untuk memprediksi masa depan. Garis orange menunjukkan prediksi model GRU dan garis hijau menunjukkan prediksi model BiLSTM tinggi muka air laut. Dapat dilihat bahwa model BiLSTM cenderung lebih banyak mendekati nilai asli dibandingkan dengan metode GRU. Perbandingan hasil prediksi dengan metode GRU dan BiLSTM pada 7 hari kedepan dapat dilihat pada Tabel III.

TABEL III
HASIL PREDIKSI METODE GRU DAN BiLSTM

No	Date	Prediksi GRU	Prediksi BiLSTM
1	01/07/2024	2.946	2.964
2	02/07/2024	2.947	2.960
3	03/07/2024	2.923	2.939
4	04/07/2024	2.873	2.898
5	05/07/2024	2.829	2.863
6	06/07/2024	2.810	2.850
7	07/07/2024	2.797	2.843

Berdasarkan Tabel III, hasil prediksi dari metode GRU dan BiLSTM menunjukkan bahwa BiLSTM cenderung memberikan nilai prediksi yang lebih konsisten dibandingkan GRU untuk rentang waktu yang dianalisis. Konsistensi prediksi BiLSTM ini mengindikasikan bahwa model tersebut mungkin lebih baik dalam mengatasi pola sederhana atau perubahan yang lebih teratur dalam data.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode BiLSTM lebih unggul dibandingkan dengan metode GRU dalam memprediksi tinggi muka air laut pada sensor waterlevel di Perairan Lampung Selatan. Hal ini terlihat dari nilai MAE dan RMSE yang diperoleh, di mana metode BiLSTM memiliki nilai MAE terendah sebesar 0.0102 dan RMSE 0.0218, sementara metode GRU memiliki nilai MAE 0.0164 dan RMSE 0.0277. Keunggulan BiLSTM dalam penelitian ini disebabkan oleh arsitekturnya yang lebih sederhana, memungkinkan model untuk lebih cepat menangkap pola selama proses pelatihan. Selain itu, hasil evaluasi menunjukkan bahwa nilai MAE dan RMSE pada metode GRU lebih fluktuatif,

yang berarti terdapat variasi error yang lebih besar dibandingkan dengan metode BiLSTM yang cenderung menghasilkan nilai evaluasi yang lebih konstan. Namun, untuk meningkatkan performa model kedepannya, perlu dilakukan optimasi parameter yang lebih spesifik, implementasi teknik regulasi, augmentasi data, dan validasi silang K-fold. Dengan strategi-strategi ini, akan dapat meningkatkan generalisasi model dan menghindari overfitting, sehingga prediktif akhir menjadi lebih akurat dan stabil.

REFERENSI

- [1] Nadya, and S. Agus, "Pengaruh Sea Level Rise Di Wilayah Perkotaan Indonesia," *J. Riset Sains Dan Teknologi Kelautan (SENSITEK)*, vol. 6, no. 1, pp. 52-55, 2023.
- [2] A. Shallsabilla, H. Setiyono, D. N. Sugianto, D. H. Ismunarti, and J. Marwoto, "Kajian Fluktuasi Muka Air Laut Sebagai Dampak dari Perubahan Iklim di Perairan Semarang," *Indonesian Journal of Oceanography (IJOCE)*, vol. 4, no. 1, pp. 69-76, 2022.
- [3] N. A. Azuga, "Kerentanan Kawasan Pesisir Terhadap Bencana Kenaikan Muka Air Laut (Sea Level Rise) di Indonesia," *J. J-Tropimar*, vol. 3, no. 2, pp. 65-79, 2021.
- [4] B. D. Dasanto, Sulistiyanti, Anria, and R. Boer, "Dampak Perubahan Iklim Terhadap Kenaikan Muka Air Laut Di Wilayah Pesisir Pangandaran," *J. Risalah Kebijakan Pertanian dan Lingkungan*, vol. 9, no. 2, pp. 82-94, 2022.
- [5] W. A. Arifin, L. O. A. Minsaris, A. A. Rosalia, A. Satibi, M. Rudi, A. Dzikrillah, M. R. Apriansyah, and E. Efendi, "Bibliometric Computational Mapping Analysis Of Publications Of Marine Information System Using Vosviewer," *Journal of Engineering Science and Technoogy*, vol. 18, no. 6, pp. 3018-3028, 2023.
- [6] A. Roihan, P. A. Sunarya, and A. S. Rafika, "Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper," *J. IJCIT (Indonesian Journal on Computer and Information Technology)*, vol. 5, no. 1, pp. 75-82, 2020.
- [7] T. O. Bagaskara, M. I. Herdiansyah, T. Sutabari, and E. S. Negara, "Model Prediksi Menggunakan Teknik Machine Learning untuk Penjualan terhadap Produksi Kain Jumputan pada Pengerajin Batiq Colet Jumputan Palembang" *J. PETIR: Jurnal Pengkajian dan Penerapan Teknik Informatika*, vol. 10, no. 2, pp. 189-199, 2023.
- [8] E. Subowo, F. A. Artanto, I. Putri, and W. Umaedi, "BLTSM untuk analisis sentimen berbasis aspek pada aplikasi belanja online dengan cicilan," *Jurnal Fasilkom*, vol. 7, no. 2, pp. 132-140, 2022.
- [9] J. K. Halim, D. E. Herwindiati, and J. Hendryli, "Penerapan Gated Recurrent Unit Untuk Prediksi Zat Pencemar Udara," *Jurnal Ilmu Komputer dan Sistem Informasi*, vol. 12, no. 2, pp. 89-99, 2022.
- [10] D. R. Alghifari, M. Edi, and L. Firmansyah, "Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia," *Jurnal Manajemen Informatika (JAMIKA)*, vol. 12, no. 2, pp. 89-99, 2022.
- [11] M. G. Rizky, "Analisis Perbandingan Metode LSTM dan BiLSTM Untuk Klasifikasi Sinyal Jantung Phonocardiogram," Universitas Dinamika, 2021.
- [12] N. K. Agusmawati, F. Khoiriyah, and A. Tholib, "Prediksi Harga Emas Menggunakan Metode Lstm Dan Gru," *J. JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 11, no. 2, pp. 620-627, 2023.
- [13] I. D. Id, "Machine Learning: Teori, Studi Kasus dan Implementasi Menggunakan Python," *UR PRESS*.
- [14] A. A. Rahman, "Implementasi Machine Learning Pada Kegiatan Application Programming Interface Untuk Klasifikasi Komentar Cyberbullying," Universitas Islam Negeri Syarif Hidayatullah Jakarta, 2023.
- [15] R. G. Whardana, G. Wang, and F. Sibuea, Penerapan Machine Learning Dalam Prediksi Tingkat Kasus Penyakit Di Indonesia. *Journal of Information System Management (JOISM)*, vol. 5, no. 2, pp. 40-45, 2023.

- [16] M. Oppenheimer, and B. Glavovic, "Sea Level Rise and Implications for Low Lying Islands, Coasts and Communities," *Cambridge University Press, Cambridge, UK and New York, NY, USA, 321-445*, 2019.
- [17] Z. Hidayah, S. A. Ilhami, A. As-Syakur, D.B. Wiyanto, and H. Wirahyuhanto, "Pemodelan Spasial Genangan Akibat Kenaikan Muka Air Laut di Pesisir Selatan Kabupaten Tulungagung Jawa Timur," *J. Kelautan Nasioanl*, vol. 18, no. 1, pp. 1-12, 2023.
- [18] Y. Prahara, and Sewaka, "Prediksi Persediaan Bahan Baku Pembuatan Pempek Menggunakan Metode Naive Bayes (Study Kasus: Home Industry Pempek Yura)," *J. Jurnal Ilmu Komputer dan Science*, vol. 3, no. 1, pp. 153-160, 2024.
- [19] N. W. M. Aryati, I. K. A. G. Wiguna, N. W. S. Putri, I. K. K. Widiartha, and N. L. W. S. R. Ginantra, "Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham," *J. Jurnal Media Informatika Budidarma*, vol. 8, no.2, pp. 1131-1140, 2024.
- [20] A. P. Meriani, and A. Rahmatulloh, "Perbandingan Gated Recurrent Unit (Gru) Dan Algoritma Long Short -Term Memory (Lstm) Linear Refression Dalam Prediksi Harga Emas Menggunakan Model Time Series," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 1, pp. 468-475, 2024.
- [21] N. Afrianto, D. H. Fudholi, and S. Rani, "Prediksi Harga Saham Menggunakan BiLSTM dengan Faktor Sentimen Publik," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 41-46, 2022.
- [22] A. A. Suryanto, and A. Muqtadir, "Penerapan Metode Mean Absolute Error (Mea) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi," *SAINTEKBU: Jurnal Sains dan Teknologi*, vol. 11, no. 1, pp. 78-83, 2019.
- [23] J. N. Gustin, and A. A. I. Pakereng, "Peramalan Trend Pendapatan di Toko Online XYZ Menggunakan Single Moving Average," *Jurnal JTIIK (Jurnal Teknologi Informasi dan Komunikasi)*, vol. 7, no. 1, pp. 130-139, 2023.
- [24] H. W. Herwanto, T. Widiyaningtias, and P. Indriana, "Penerapan Algoritme Linear Regression untuk Prediksi Hasil Panen Tanaman Padi," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, vol. 8, no. 4, pp. 2019.