

## Analisis Prediksi Kenaikan Permukaan Laut Menggunakan Data Satelit Altimetri dengan LSTM di Perairan Jepara dan Sekitarnya

Refaldi Rizky Maulana, Baskoro Rochaddi\*, Yusuf Jati Wijaya

Departemen Oseanografi, Fakultas Perikanan dan Ilmu Kelautan, Universitas Diponegoro  
Jl. Prof. Jacob Rais, Tembalang Semarang, Jawa Tengah 50265 Indonesia  
Email: brochaddi@gmail.com

### Abstrak

Perubahan iklim global telah menyebabkan kenaikan permukaan laut yang signifikan, yang mengancam negara kepulauan seperti Indonesia. Penelitian ini berfokus pada wilayah Jepara, Jawa Tengah, yang berbatasan dengan Laut Jawa dan rentan terhadap kenaikan permukaan laut. Penelitian ini bertujuan untuk menganalisis dan mencari hubungan antara pasang surut dan *Sea Level Anomaly* (SLA), serta mengevaluasi model *Long Short-Term Memory* (LSTM) dalam memprediksi data SLA di Jepara. Penelitian ini menggunakan data SLA komponen *Delayed Time* (DT) dan *Near-Real Time* (NRT) dari *Copernicus Marine Environment Monitoring Service* (CMEMS) dan data pasang surut dari Badan Informasi Geospasial (BIG). Hasil analisis menunjukkan bahwa pasang surut di perairan Jepara cenderung bersifat campuran condong ke harian tunggal. Hasil korelasi Pearson yang linear positif yang kuat dan koefisien determinasi sebesar 52,01% pada *dataset* komponen DT dengan 4 titik pengamatan di perairan Jepara menunjukkan bahwa peningkatan SLA berhubungan dengan peningkatan pasang surut, di mana SLA menjelaskan 52,01% variasi pasang surut. Tren kenaikan SLA dari tahun 1993 hingga 2023 menunjukkan rata-rata kenaikan permukaan laut sebesar 4,794 mm/tahun, dengan puncak tertinggi pada tahun 2022. Model LSTM dengan 2 *hidden layers*, 100 *epochs*, 100 *hidden units*, dan *dropout rate* 0,1 menunjukkan kinerja yang baik dalam memprediksi data SLA, dengan MAE sebesar 2,3776, RMSE 3,0389, dan MAPE 17%. Hasil evaluasi tersebut menunjukkan nilai *error* yang kecil, sehingga dapat disimpulkan bahwa model LSTM memiliki performa yang baik dalam memprediksi kenaikan permukaan laut.

**Kata kunci :** Kenaikan permukaan laut, *Long Short-Term Memory*, *hyperparameter tuning*, perairan Jepara

### Abstract

#### *Analysis of Sea Level Rise Prediction Using Satellite Altimetry Data and LSTM in the Jepara Coastal Waters and Surrounding Region*

*Global climate change has caused significant sea level rise, which threatens archipelagic countries like Indonesia. This research focuses on the Jepara region in Central Java, which borders the Java Sea and is vulnerable to rising sea levels. The study aims to analyze and identify the relationship between tides and Sea Level Anomaly (SLA), and evaluate the Long Short-Term Memory (LSTM) model in predicting SLA data in Jepara. The research uses Delayed Time (DT) and Near-Real Time (NRT) SLA data from the Copernicus Marine Environment Monitoring Service (CMEMS) and tidal data from Badan Informasi Geospasial (BIG). The results of the analysis show that the tides in Jepara waters tend to be mixed tide prevailing diurnal. The strong positive linear Pearson correlation and a 52.01% coefficient of determination in the DT component dataset with 4 observation points in Jepara waters indicate that the increase in SLA is related to the increase in tides, where SLA explains 52.01% of the tidal variation. The SLA trend from 1993 to 2023 shows an average sea level rise of 4,794 mm/year, with the maximum height in 2022. The LSTM model with 2 hidden layers, 100 epochs, 100 hidden units, and a dropout rate of 0.1 demonstrated good performance in predicting SLA data, with an MAE of 2.3776, RMSE of 3.0389, and MAPE of 17%. These results indicate that the LSTM model performs well in predicting sea level rise.*

**Keywords:** *Sea level rise, Long Short-Term Memory, hyperparameter tuning, Jepara waters*

---

\*Corresponding author

DOI:10.14710/buloma.v14i2.67069

<http://ejournal.undip.ac.id/index.php/buloma>

Diterima/Received : 26-01-2025

Disetujui/Accepted : 30-04-2025

## PENDAHULUAN

Perubahan iklim global telah menyebabkan kenaikan permukaan laut yang signifikan, mengancam berbagai kawasan pesisir di seluruh dunia, terutama di negara kepulauan seperti Indonesia. Menurut Mujadida *et al.* (2021), laut Jawa adalah salah satu wilayah di Indonesia yang mengalami dampak terbesar. Kabupaten Jepara yang terletak di bagian utara Pulau Jawa dan berbatasan langsung dengan Laut Jawa, menghadapi risiko besar akibat kenaikan permukaan laut, yang mencakup peningkatan frekuensi banjir, erosi pantai yang parah, dan kerugian ekonomi signifikan di daerah pesisir yang padat penduduk. Risiko ini tidak hanya mengancam ekosistem pesisir tetapi juga mempengaruhi kehidupan masyarakat yang bergantung pada sumber daya laut, menjadikannya isu yang mendesak untuk ditangani. Oleh karena itu, memahami estimasi muka air laut menjadi prioritas utama dan menarik minat besar di kalangan peneliti, pemerintah dan pemangku kepentingan lainnya. Hal tersebut diperkuat oleh Clark *et al.* (2015), memahami dan memproyeksikan perubahan rata-rata permukaan laut regional dan global sangat penting untuk menilai dampak sosial-ekonomi dan merencanakan adaptasi di zona pesisir rendah yang padat penduduk di seluruh dunia. Untuk mencapai pemahaman mengenai perubahan muka air laut ini, berbagai metode pengukuran digunakan. Saat ini, pengukuran permukaan laut umumnya dilakukan dengan menggunakan pengukur pasang surut (*tide gauge*) dan satelit altimetri.

Menurut Adebisi *et al.* (2021), pengukuran permukaan laut telah berkembang pesat, dari penggunaan tiang pasang surut pada 1770-an hingga adopsi teknologi modern seperti radar dan satelit altimetri. Meski alat pengukur pasang surut (*relative sea level*) yang diukur di pesisir dapat memahami perubahan permukaan laut lokal, tetapi ada faktor pergerakan vertikal tanah (*vertical land motion*) di pesisir, sehingga faktor ini penting diperhitungkan untuk mendapatkan estimasi *Absolute Sea Level* (ASL) yang lebih tepat. Selain itu, sejak diperkenalkan pada 1990-an, teknologi satelit altimetri telah berkembang dengan sangat pesat dan kini mampu menyediakan data permukaan laut global ASL tentang ketinggian permukaan laut dengan presisi tinggi di laut terbuka. Data satelit altimetri dan pasang surut ini menjadi sangat penting dalam memahami dampak perubahan iklim terhadap kenaikan permukaan laut

di perairan Jepara. Selain itu, satelit altimetri memberikan informasi yang berguna untuk analisis pemantauan kenaikan permukaan laut, di mana kenaikan muka air laut dapat dideteksi dari SLA yang didapat dari pengamatan satelit altimetri. Penelitian ini berusaha untuk memahami data SLA ini untuk memperjelas tren dan pola kenaikan permukaan laut di perairan Jepara.

*Artificial neural networks*, yang merupakan struktur lapisan dalam *deep learning*, memiliki tumpukan lapisan yang memungkinkan pemodelan otomatis dari data pelatihan tanpa membentuk model yang identik dengan fungsi otak manusia (Chollet, 2018). Metode *deep learning*, khususnya (LSTM), terbukti efektif dalam memprediksi perubahan permukaan laut. LSTM, yang dirancang untuk memproses data *time series* yang kompleks, serta meningkatkan akurasi prediksi dengan menangkap pola jangka panjang dalam data yang tidak dapat ditangkap oleh metode konvensional (Sorkhabi *et al.*, 2023). Prediksi kenaikan permukaan laut sangat penting untuk dilakukan, mengingat hubungan langsungnya dengan upaya mitigasi terhadap bencana yang diakibatkan oleh kenaikan permukaan laut. Selain itu, *hyperparameter tuning* memainkan peran penting dalam memaksimalkan performa model untuk memperoleh hasil prediksi yang lebih akurat. Penelitian ini bertujuan untuk mengidentifikasi tipe dan karakteristik pasang surut di Jepara, Jawa Tengah, serta menganalisis korelasi Pearson dan koefisien determinasi antara pasang surut dengan SLA. Selain itu, penelitian ini akan mengidentifikasi pola dan tren SLA dan melakukan evaluasi mendalam terhadap *hyperparameter* dan akurasi model LSTM dalam memprediksi SLA di perairan Jepara.

## MATERI DAN METODE

Materi penelitian terkait kenaikan permukaan laut ini melibatkan data primer dan sekunder. Data utama (data primer) yang digunakan adalah data satelit altimetri dari *Copernicus Marine Environment Monitoring Service* (CMEMS) berupa SLA komponen DT yang mencakup data *multi-mission* sejak 1 Januari 1993 - 7 Juni 2023. Data sekunder yang mendukung penelitian ini meliputi data pasang surut dari Badan Informasi Geospasial (BIG) dan data SLA komponen NRT dari CMEMS pada periode 1 Januari 2022 – 30 September 2022. Metode penelitian ini menggunakan pendekatan kuantitatif, yaitu penelitian yang menggunakan

angka dan menampilkan data numerik dengan gambar, tabel, grafik, atau visual lainnya (Machali, 2021). Tipe pasang surut ditentukan dengan program *World Tides*, sedangkan nilai *Mean Sea Level* (MSL), *Low Water Level* (LWL), dan *High Water Level* (HWL) dihitung secara statistik menggunakan *Python*. Untuk menganalisis hubungan antara data pasang surut dan SLA pada tahun 2022, serta metode deskriptif untuk menggambarkan tren kenaikan muka air laut di perairan Jepara berdasarkan analisis temporal SLA. Data SLA ini digunakan untuk menguji efektivitas model LSTM dalam memprediksi kenaikan permukaan laut.

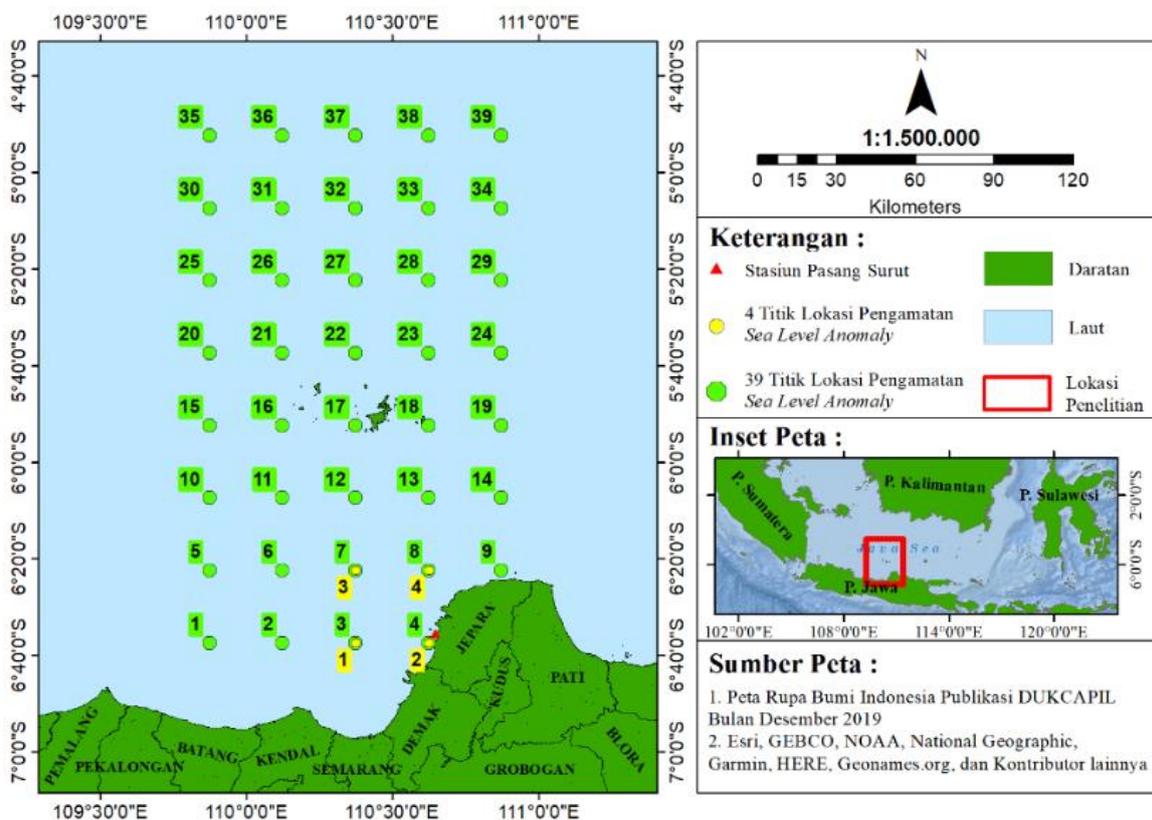
**Metode Pengumpulan Data**

Data pasang surut diunduh melalui BIG selama 9 bulan pada periode 1 Januari 2022 – 30 September 2022 yang diunduh dari <http://ina-sealevelmonitoring.big.go.id/>. Data SLA dari satelit altimetri melalui CMEMS yang dapat diunduh <https://marine.copernicus.eu/>. Data SLA terdiri dari komponen DT dari 1 Januari 1993 – 7 Juni 2023 dan NRT dari 1 Januari 2022 – 30

September 2022. Data SLA dihasilkan menggunakan data level 4 dengan resolusi spasial 0,25° x 0,25°. Lokasi data SLA melibatkan pemilihan titik pengamatan di 4 titik dan 39 titik di perairan Jepara dan sekitarnya, dengan tujuan untuk mengoptimalkan analisis terhadap kenaikan permukaan laut yang terjadi di perairan Jepara. Perairan dengan 39 titik pengamatan SLA memberikan pandangan perairan yang luas, sedangkan 4 titik pengamatan memberikan gambaran perairan yang lebih spesifik, dengan data pasang surut sebagai referensi untuk menilai efektivitas titik pengamatan SLA dalam menggambarkan kenaikan permukaan laut di perairan Jepara. Lokasi pada penelitian ini dapat dilihat pada Gambar 1.

**Metode Analisis dan Pengolahan Data Pengolahan Data Pasang Surut**

Pengolahan data pasang surut ini dilakukan selama 9 bulan dari tanggal 1 Januari 2022 – 30 September 2022, dilakukan dengan menggunakan program *World Tides* untuk menentukan tipe pasang surut. Menurut Andriansyah *et al.* (2017),



**Gambar 1.** Lokasi Penelitian

tipe pasang surut dapat diketahui dengan menghitung nilai bilangan *Formzahl* (F), yang diperoleh dengan menggunakan empat nilai konstanta ( $M_2$ ,  $S_2$ ,  $K_1$ , dan  $O_1$ ) melalui persamaan berikut :

$$F = \frac{O_1 + K_1}{M_2 + S_2}$$

Keterangan:  $O_1$  = amplitudo komponen pasut tunggal gaya tarik bulan;  $K_1$  = amplitudo komponen pasut tunggal gaya tarik matahari;  $M_2$  = amplitudo komponen pasut ganda gaya tarik bulan;  $S_2$  = amplitudo komponen pasut tunggal gaya tarik matahari

Data yang dimasukkan mencakup ketinggian muka air, Jam, dan tanggal pengambilan data. Untuk data MSL, LWL, dan HWL dihitung menggunakan *Python* dan *library Pandas* untuk analisis statistik dan visualisasi. Sebagai *library Python* untuk analisis data, *Pandas* memungkinkan pembacaan data dalam format CSV. Hasil dari pengolahan data pasang surut, yaitu tipe pasang surut, MSL, LWL, dan HWL, yang memberikan gambaran tentang karakteristik dan tipe pasang surut di perairan Jepara (Andriansyah et al. 2017).

### Analisis Korelasi Pearson dan Koefisien Determinasi

Analisis korelasi Pearson yang dilakukan selama periode 1 Januari hingga 30 September 2022, digunakan untuk mengukur hubungan antara pasang surut dan SLA. Menurut Rosalina et al. (2023), koefisien korelasi yang memiliki rentang nilai antara -1,00 hingga +1,00. Rumus yang digunakan dalam melakukan analisis korelasi Pearson adalah sebagai berikut:

$$r_{xy} = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{\{n \sum x^2 - (\sum x)^2\} \{n \sum y^2 - (\sum y)^2\}}}$$

Keterangan :  $r_{xy}$ = koefisien korelasi; x = variabel terikat; y= variabel bebas; n = banyaknya subjek yang diteliti

Koefisien Determinasi ( $r^2$ ) mengukur seberapa baik variabel independen (X) menjelaskan variabel dependen (Y), dan selalu berada dalam rentang 0 hingga 1, berbeda dengan koefisien korelasi (r) yang berkisar antara -1 hingga +1. Menurut Pagiu dan Pundissing (2022),

**Tabel 1.** Interpretasi Koefisien Korelasi antara Variabel

Nilai	Interpretasi
0,00 – 0,199	Sangat Rendah
0,20 – 0,399	Rendah
0,40 – 0,599	Sedang
0,60 – 0,799	Kuat
0,80 – 1,000	Sangat Kuat

besarnya koefisien determinasi adalah hasil kuadrat dari koefisien korelasi (r) dan dihitung dengan rumus sebagai berikut:

$$KD = r^2 \times 100\%$$

Keterangan : KD = koefisien determinasi; r = koefisien korelasi

Data SLA dihasilkan dengan interpolasi optimal menggunakan fungsi korelasi realistis dan untuk analisis lebih lanjut. Berdasarkan kajian yang dilakukan Han et al. (2023), CMEMS menyediakan data perubahan permukaan laut dengan resolusi 0,25°x0,25° dalam harian, dengan komponen DT dan NRT yang diukur pada pukul 00:00 UTC setiap hari. Dari data ini, nantinya dipisahkan menjadi dua kelompok, yaitu 39 titik dan 4 titik, untuk proses agregasi guna menghasilkan satu nilai rata-rata SLA pada setiap waktu tertentu sesuai kebutuhan penelitian. Dalam penelitian mengenai korelasi antara pasang surut dengan data SLA dari 39 dan 4 titik pengamatan, hanya data harian dari pasang surut yang diambil, yaitu nilai pada pukul 00:00:00 setiap hari dan nilai dari sensor radar. Nilai SLA dan pasang surut yang digunakan dalam data ini dinyatakan dalam satuan meter. Analisis ini dilakukan untuk menentukan apakah *dataset* SLA komponen DT atau NRT serta titik pengamatan mana yang lebih efektif dalam menjelaskan perubahan muka air laut pasang surut.

### Pemodelan

Menurut Fahrudin et al. (2024), pemodelan adalah proses menciptakan dan melatih model matematika atau algoritma untuk memahami, menganalisis, dan memprediksi data. Pemodelan LSTM untuk memprediksi data, melalui beberapa tahapan, tahapan tersebut dapat dijelaskan sebagai berikut:

**Preprocessing Data:** Tahap *preprocessing* dalam pemodelan LSTM melibatkan pembagian

*dataset* menjadi 80% data *training* dan 20% data *testing*, serta normalisasi menggunakan *Min-MaxScaler* untuk memastikan konsistensi nilai dan efektivitas pembelajaran model. Persamaan normalisasi menggunakan metode *Min-MaxScaler*, berikut ini adalah persamaannya:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

Keterangan: X' = nilai hasil normalisasi; X = nilai data aktual yang akan dinormalisasi; X<sub>min</sub> = nilai minimum dari data aktual; X<sub>max</sub> = nilai maksimum dari data aktual

Kemudian, data diproses dengan membagi menjadi jendela waktu 60 hari, di mana data *training* mencakup awal *dataset* hingga sebelum data *testing*, data *testing* yang mencakup akhir *dataset* termasuk jendela waktu. Data diubah menjadi *array numpy* dan disesuaikan dengan format *input* model LSTM untuk memastikan kesiapan data dalam pelatihan. *Preprocessing* ini memastikan bahwa data siap untuk digunakan dalam tahap pelatihan model, dengan struktur yang sesuai dan dalam skala yang konsisten.

**Hyperparameter tuning:** *Hyperparameter* seperti *hidden layer*, *epochs*, *hidden units*, dan *dropout rate* diatur secara manual untuk mengoptimalkan performa model LSTM. Pada tahap ini, *hyperparameter tuning* dilakukan agar model LSTM dapat mempelajari pola-pola dalam data dengan efektif. Pengaturan yang tepat dari *hyperparameter* ini akan menentukan seberapa baik model dapat menangkap pola dari data dan mengoptimalkan kemampuannya dalam menghasilkan prediksi yang akurat.

**Training Model:** Proses *training* model bertujuan untuk menemukan bobot yang optimal agar model dapat memprediksi data dengan akurat melalui beberapa *epochs*, di mana setiap *epochs* melibatkan satu iterasi lengkap melalui seluruh data *training*. Selama pelatihan, model diperbarui untuk meningkatkan akurasi prediksi, dengan pengaturan *hyperparameter* seperti jumlah *epochs* dan *batch size* mempengaruhi waktu serta efektivitas pelatihan. Selain itu, model LSTM menggunakan fungsi aktivasi *tanh* dan dikompilasi dengan *loss* MSE serta *Adam optimizer* untuk pembaruan bobot yang efisien. Dalam penelitian ini, *batch size* 32 dipilih karena merupakan ukuran yang umum digunakan.

**Denormalisasi:** Proses denormalisasi dilakukan dengan tujuan untuk menyederhanakan

pembacaan dan interpretasi nilai keluaran yang dihasilkan. Proses ini penting untuk memastikan bahwa nilai keluaran yang dihasilkan dapat dipahami dan diinterpretasikan dengan lebih mudah. Dengan mengembalikan hasil ke skala asli, proses ini memastikan bahwa nilai keluaran dapat dipahami dengan lebih mudah dan relevan untuk analisis lebih lanjut. Berikut ini adalah rumus yang digunakan untuk proses denormalisasi:

$$d = d'(\max - \min) + \min$$

Keterangan: d = nilai hasil denormalisasi; d' = nilai hasil normalisasi; max = nilai maksimum dari data aktual; min = nilai minimum dari data aktual

**Evaluasi Model:** Evaluasi model ini menilai seberapa baik model yang dikembangkan dalam memprediksi hasil yang diinginkan. Metrik evaluasi seperti *Root mean squared error* (RMSE), *mean absolute error* (MAE), dan *mean absolute percentage error* (MAPE). Metrik tersebut digunakan untuk mengukur akurasi prediksi model dengan membandingkan hasil prediksi dengan data sebenarnya (*aktual*). Menurut Lee *et al.* (2018), persamaan yang digunakan dalam metrik evaluasi model dapat dituliskan sebagai berikut :

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}}$$

$$MAE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n}$$

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} \times 100\%$$

Keterangan: y<sub>t</sub> = nilai aktual; ŷ<sub>t</sub> = nilai prediksi; n = jumlah data;

Jika nilai RMSE, MAE, dan MAPE yang mendekati 0 menunjukkan bahwa model memiliki kinerja yang sangat baik dengan kesalahan prediksi yang kecil (Amansyah *et al.*, 2024).

## HASIL DAN PEMBAHASAN

Berdasarkan hasil analisis data pasang surut di perairan Jepara yang didapatkan dari BIG selama 9 bulan dari 1 Januari 2022 – 30 September 2022, dapat diketahui tipe pasang surut, MSL, LWL, dan HWL yang disajikan pada Tabel 2.

Hasil analisis data pasang surut bulanan di perairan Jepara tahun 2022 menunjukkan tipe pasang surut lebih dominan campuran condong

harian tunggal (*mixed tide prevailing diurnal*) dengan rentang nilai Formzahl  $1.5 < F \leq 3$ , di mana dalam sehari terjadi satu kali pasang dan satu kali surut, meskipun terkadang dapat terjadi dua kali pasang dan dua kali surut dengan variasi tinggi dan periode. Analisis ini sejalan dengan penelitian Sihotang *et al.* (2020), yang juga menemukan tipe pasang surut campuran condong ke harian tunggal di perairan Jepara. Nilai *Low Water Level* (LWL) berkisar antara 0,64 hingga 0,84 meter, menunjukkan titik terendah air laut yang stabil secara relatif sepanjang tahun. Nilai *Mean Sea Level* (MSL) berada dalam rentang 1,11 hingga 1,27 meter, mencerminkan ketinggian rata-rata yang stabil dengan variasi minim. Nilai *High Water Level* (HWL) berkisar antara 1,66 hingga 3,66 meter, menunjukkan puncak tertinggi dengan fluktuasi yang lebih besar. Nilai HWL yang mencapai 3,66 meter pada 20 Mei 2022, pukul 09.00 UTC, menunjukkan banjir rob akibat kenaikan muka air laut ke daratan, sementara nilai pasang surut lainnya di bulan Mei berada dalam rentang normal. Menurut Nugraha (2022), banjir rob di pesisir utara Jawa disebabkan oleh gelombang badai (*storm surge*) akibat hujan deras dan angin kencang di Laut Jawa antara 19-22 Mei 2022, yang menyebabkan kenaikan signifikan dalam muka air laut. Fenomena ini, dipicu oleh siklon tropis, menghasilkan gelombang tinggi dan tekanan rendah yang meningkatkan ketinggian air secara tiba-tiba, mengakibatkan banjir rob dan dampak parah pada pesisir (Syarifullah, 2015). Meskipun analisis ini memberikan gambaran fluktuasi muka air laut, hal ini tidak secara langsung mencerminkan tren kenaikan permukaan laut jangka panjang yang dipengaruhi oleh perubahan iklim dan penurunan muka tanah.

### Korelasi Pearson dan Koefisien Determinasi antara Pasang Surut dengan *Sea Level Anomaly*

Hasil uji korelasi Pearson dan koefisien determinasi antara data pasang surut dengan SLA pada 4 titik pengamatan dan 39 titik pengamatan, disajikan pada Gambar 2. Hasil uji korelasi Pearson yang dilakukan pada tanggal 1 Januari 2022 hingga 30 September 2022 menunjukkan bahwa data pasang surut menunjukkan peningkatan yang konsisten dalam muka air laut, sedangkan data SLA menunjukkan fluktuasi yang lebih stabil tanpa adanya peningkatan yang signifikan. Berdasarkan Gambar 2 menunjukkan hasil uji korelasi Pearson dan koefisien determinasi antara pasang surut dengan SLA. Untuk komponen DT, nilai korelasi Pearson pada 39 titik pengamatan adalah 0,6511 dengan koefisien determinasi 0,4239. Pada 4 titik pengamatan, korelasi Pearson meningkat menjadi 0,7212 dengan koefisien determinasi 0,5201. Untuk komponen NRT, pada 4 titik pengamatan, korelasi Pearson adalah 0,7134 dengan koefisien determinasi 0,5089, menjelaskan 50,89% variasi pasang surut. Sebaliknya, pada 39 titik pengamatan, nilai korelasi Pearson adalah 0,6455 dengan koefisien determinasi 0,4167, menjelaskan 41,67% variasi pasang surut. Perbedaan tersebut menunjukkan bahwa pada 39 titik pengamatan di perairan Jepara dan sekitarnya masih menunjukkan adanya hubungan atau pengaruh antara SLA dengan pasang surut, meskipun tidak sekuat pengamatan pada 4 titik pengamatan. Selain itu, perbedaan kecil dalam nilai korelasi Pearson dan koefisien determinasi antara 4 titik dan 39 titik pengamatan menunjukkan hubungan yang konsisten, namun perairan dengan 4 titik pengamatan lebih efektif dalam menjelaskan variasi pasang surut.

**Tabel 2.** Hasil Perhitungan LWL, MSL, HWL, dan Nilai Formzahl Perairan Jepara Tahun 2022

Bulan	LWL (m)	MSL (m)	HWL (m)	Nilai Formzahl
Januari	0,64	1,11	1,73	2,46
Februari	0,73	1,13	1,66	1,92
Maret	0,71	1,14	1,69	1,48
April	0,69	1,19	1,77	1,55
Mei	0,67	1,27	3,66	2,16
Juni	0,76	1,27	1,86	3,16
Juli	0,71	1,23	1,83	3,46
Agustus	0,74	1,21	1,74	2,76
September	0,84	1,20	1,77	2,08

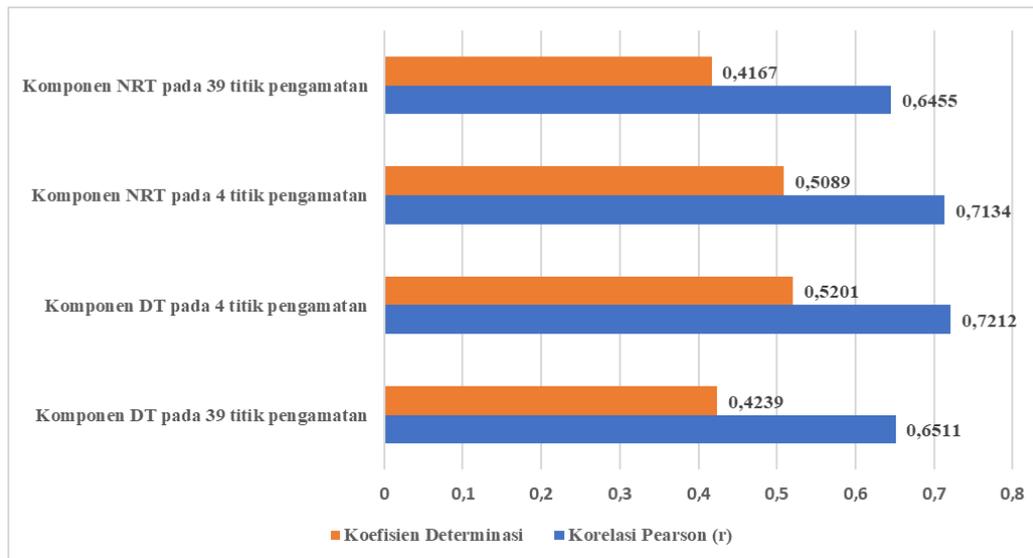
Hasil Penelitian ini menunjukkan bahwa pengamatan pada *dataset* SLA komponen DT pada 4 titik pengamatan memberikan korelasi dan koefisien determinasi yang sedikit lebih kuat antara pasang surut dengan SLA, kemungkinan hal ini terjadi karena pengamatan yang lebih terfokus menangkap variasi lokal dengan lebih baik. Kesimpulannya *dataset* SLA komponen DT pada 4 titik pengamatan lebih efektif untuk menggambarkan perubahan permukaan laut di perairan Jepara. Oleh karena itu, pemilihan *dataset* DT dengan 4 titik pengamatan dalam penelitian ini dilakukan untuk memahami kenaikan permukaan laut. Hal ini didasarkan pada keunggulan data DT yang mencakup rentang waktu yang lebih luas, mulai dari tahun 1993 sampai 2023, berbeda dengan data NRT yang hanya tersedia mulai tahun 2022. Keunggulan data DT diperkuat oleh Nababan *et al.* (2015), di mana komponen DT lebih akurat dibandingkan komponen NRT karena merupakan hasil gabungan dari semua satelit altimetri dengan periode waktu panjang. Hal ini membuat data SLA komponen DT direkomendasikan untuk memberikan gambaran tentang kenaikan muka air laut.

**Pola dan Tren Sea Level Anomaly Perairan Jepara**

Dalam analisis ini, digunakan *dataset* SLA komponen DT pada 4 titik pengamatan, dengan mengubah satuan dari meter ke milimeter untuk meningkatkan akurasi dan mendeteksi perubahan

kecil. Hasil *Exploratory Data Analysis* (EDA) ditampilkan pada Tabel 3.

Dari tabel 3, dapat diketahui nilai rata-rata *dataset* SLA komponen DT pada 4 titik pengamatan di perairan Jepara selama 1993-2023 adalah 49,247 mm dengan standar deviasi 78,366 mm. Nilai standar deviasi yang lebih besar dari rata-rata (*mean*) menandakan adanya variasi yang signifikan dalam data, yang mungkin disebabkan oleh faktor-faktor seperti fluktuasi besar atau keanekaragaman yang tinggi dalam *dataset*. Nilai minimum dan maksimum masing-masing adalah -155,525 mm dan 332,125 mm. Analisis data ini penting untuk memahami pola dan tren serta untuk pengambilan keputusan yang lebih baik. Dalam penelitian ini, melakukan analisis terhadap data sangat penting untuk memahami pola dan tren yang mungkin tersembunyi di balik kompleksitas data. Selain itu, pemahaman terhadap kualitas data sangat penting untuk mengatasi masalah seperti data yang hilang atau duplikat yang dapat mempengaruhi akurasi model. Selanjutnya, menentukan periode waktu yang tepat untuk pembagian data menjadi *training* dan *testing* juga merupakan bagian penting dari proses analisis. Dengan memahami *dataset* ini melalui metode *Exploratory Data Analysis* (EDA), akan diperoleh wawasan berharga yang membantu dalam membuat keputusan yang lebih baik serta menyiapkan data secara optimal untuk pemodelan LSTM.



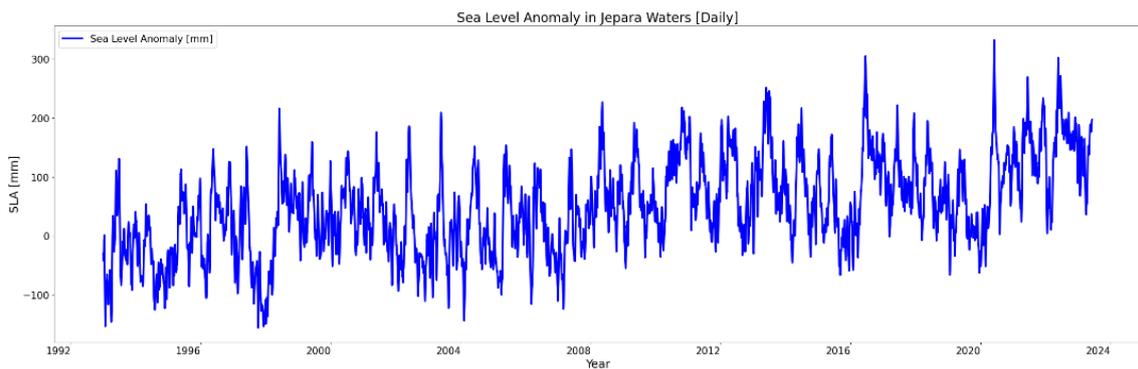
**Gambar 2.** Hasil Uji Korelasi Pearson dan Koefisien Determinasi antara Pasang Surut dengan SLA

Grafik SLA harian dari tahun 1993 hingga 2023 yang dihasilkan dari *dataset* ini dapat memberikan gambaran yang komprehensif tentang variasi ketinggian permukaan laut selama tiga dekade terakhir. Grafik ini, yang ditampilkan pada Gambar 3, secara jelas memperlihatkan fluktuasi harian dalam data SLA, mencerminkan perubahan

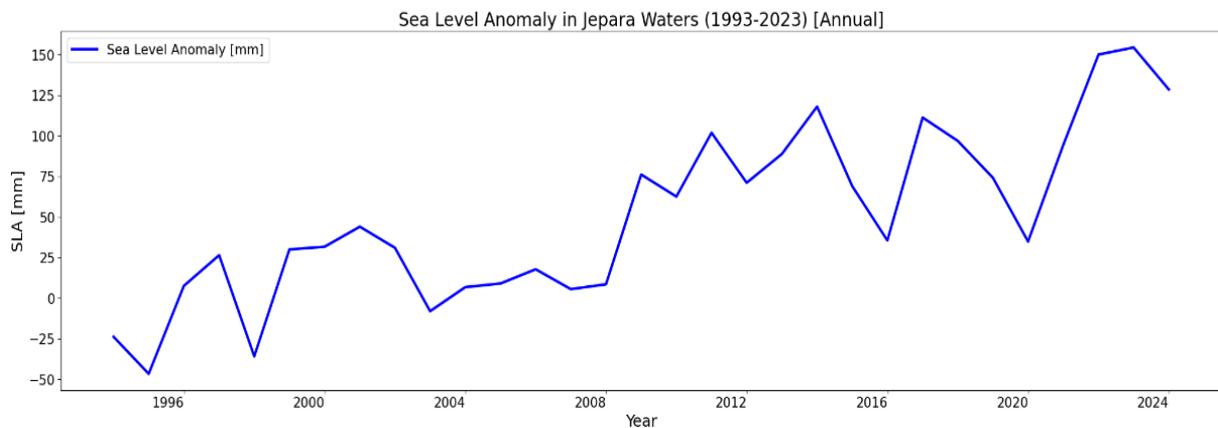
yang terjadi dari waktu ke waktu. Melalui analisis mendalam terhadap grafik ini, kita dapat memahami pola perubahan permukaan laut dari waktu ke waktu. Pemahaman yang mendalam tentang pola ini penting untuk mengantisipasi dampak kenaikan permukaan laut di masa depan.

**Tabel 3.** Distribusi Data SLA

	SLA
Count	11115
Mean	49,247411
Std	78,366289
Min	-155,52500
25%	-5,850
50%	45,550
75%	103,725
Max	332,125



**Gambar 3.** SLA Komponen DT Harian di Perairan Jepara Tahun 1993-2023 pada 4 Titik Pengamatan



**Gambar 4.** SLA Komponen DT Rata-rata Tahunan di Perairan Jepara Tahun 1993-2023 pada 4 Titik Pengamatan

Hasil dari *resampling* ini memberikan gambaran yang lebih jelas mengenai tren kenaikan permukaan laut dari tahun ke tahun. Grafik hasil *resampling* yang ditampilkan pada Gambar 4, memudahkan analisis tren perubahan permukaan laut dari tahun ke tahun. Dengan adanya grafik ini memungkinkan mendapatkan pemahaman yang lebih baik mengenai pola perubahan permukaan laut dan fluktuasi tahunan yang mungkin tidak tampak pada data harian. Identifikasi fluktuasi tahunan ini penting untuk memahami tren perubahan permukaan laut di perairan Jepara. Selain itu, rata-rata kenaikan permukaan laut di perairan Jepara dapat dilihat pada Gambar 5.

Berdasarkan Gambar 5, regresi linear didapat, kemudian analisis tren linier pada nilai tersebut menghasilkan persamaan berikut:  $y = 4,794x - 9575,6$ .

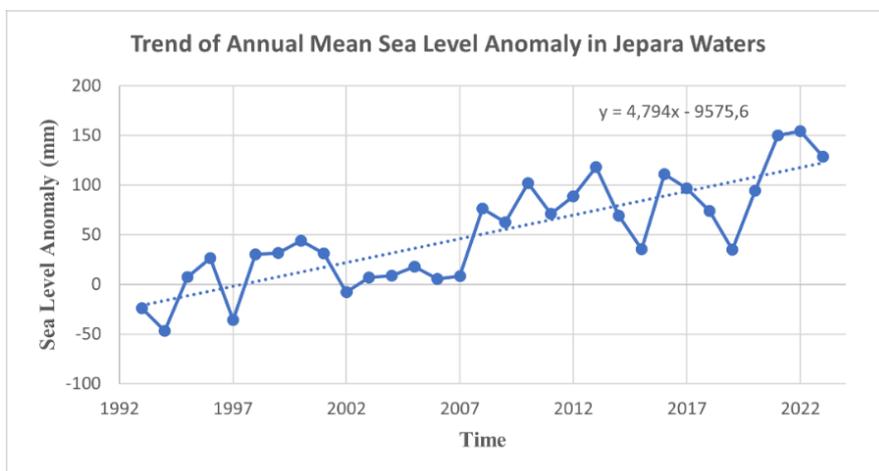
Variabel  $y$  mewakili SLA dalam milimeter dan variabel  $x$  adalah waktu dalam tahun. Persamaan ini menunjukkan bahwa tren linier memiliki kemiringan positif, yang berarti terdapat peningkatan rata-rata SLA atau kenaikan permukaan laut sebesar 4,794 mm/tahun. Grafik SLA harian di perairan Jepara dari 1993 hingga 2023 memperlihatkan fluktuasi yang mencolok setiap harinya. Variasi harian ini mencerminkan dinamika jangka pendek dalam kenaikan permukaan laut, yang dipengaruhi oleh berbagai faktor lingkungan. Grafik SLA rata-rata tahunan di perairan Jepara dari 1993 hingga 2023 menunjukkan variasi signifikan setiap tahunnya. Hal ini menunjukkan bahwa, secara umum, permukaan laut di perairan Jepara mengalami peningkatan sebesar 4,794 mm setiap tahun dari

1993 hingga 2023. Kenaikan permukaan laut di perairan Jepara, hampir setara dengan angka kenaikan permukaan laut Indonesia secara umum, yaitu 4,6 mm/tahun (Handoko *et al.*, 2019). Hal ini mengindikasikan peningkatan yang berkelanjutan dan potensi terjadinya penenggelaman di beberapa kawasan.

Nilai SLA berkisar dari -46,61 mm pada 1994 hingga 154,40 mm pada 2022. Pada tahun-tahun awal, seperti 1993, 1994, 1997, dan 2002, menunjukkan anomali negatif, mengindikasikan penurunan permukaan laut, namun sebagian besar tahun mencatat kenaikan yang signifikan. Pada tahun 2000 hingga 2022 menunjukkan tren kenaikan konsisten, mencerminkan kecenderungan jangka panjang menuju kenaikan permukaan laut, terutama dalam dua dekade terakhir. Hal tersebut mengindikasikan adanya kenaikan permukaan laut akibat perubahan iklim. Kondisi tersebut diperparah dengan adanya penurunan muka tanah yang merupakan ancaman yang lebih besar terhadap kenaikan permukaan laut, karena fenomena ini memperburuk dampak dari naiknya muka air laut (Andnur *et al.*, 2022).

**Evaluasi Hyperparameter Model**

Dalam Penelitian ini dilakukan beberapa pengaturan *hyperparameter* atau *hyperparameter tuning*. Pengaturan *hyperparameter* dilakukan agar model LSTM dapat mempelajari pola-pola dalam data dengan efektif. Pengaturan yang tepat dari *hyperparameter* ini akan menentukan seberapa baik model dapat menangkap fitur dari data dan mengoptimalkan kemampuannya dalam menghasilkan prediksi yang akurat. Dalam



**Gambar 5.** Rata-rata Kenaikan Permukaan Laut di Perairan Jepara

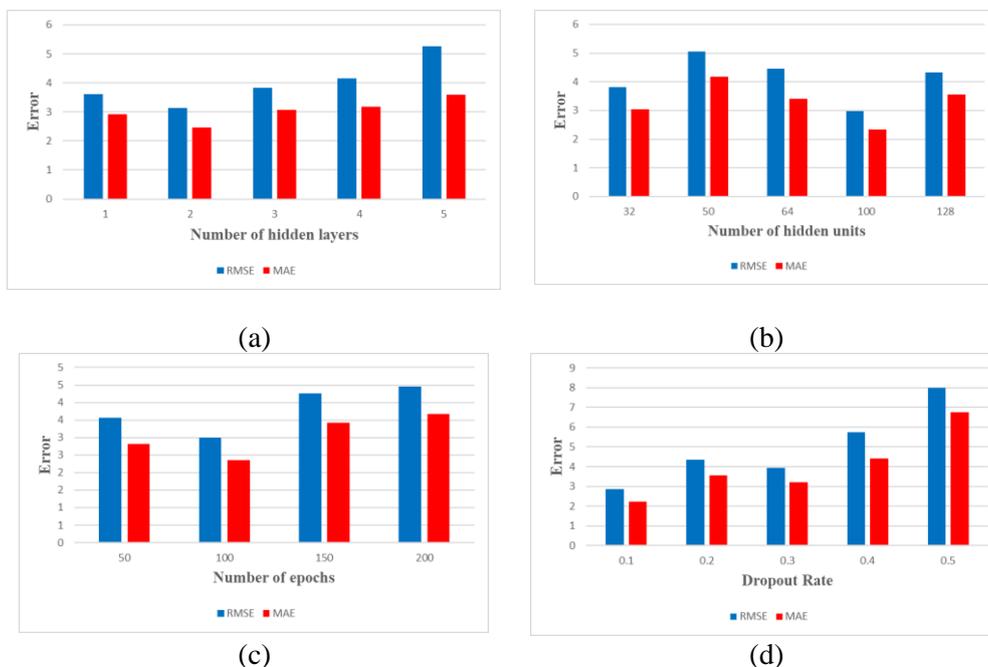
penelitian ini, *Manual Hyperparameter Tuning* digunakan untuk proses penentuan *hyperparameter* secara manual berdasarkan evaluasi individu, yang melibatkan pemilihan, pelatihan, dan evaluasi model untuk menemukan kombinasi yang memberikan hasil terbaik, tanpa menggunakan teknik optimasi otomatis (Hossain dan Timmer, 2021). Untuk hasil percobaan mencari *hyperparameter* yang optimal ditunjukkan pada Gambar 6.

Berdasarkan Gambar 6, hasil evaluasi *hyperparameter* model pada model LSTM menunjukkan kemampuannya untuk memprediksi data yang belum pernah dilihat sebelumnya atau data *testing*. Model LSTM dengan dua *hidden layers* memberikan performa terbaik dengan nilai RMSE sebesar 3,1329 dan MAE sebesar 2,4579 pada data *testing*. Selain itu, model yang dilatih dengan 100 *epochs* mencapai nilai RMSE sebesar 2,9859 dan MAE sebesar 2,3441, menunjukkan akurasi prediksi yang lebih baik dibandingkan dengan *epochs* lainnya. Model dengan 100 *hidden units* juga menunjukkan hasil yang optimal dengan nilai RMSE sebesar 2,9721 dan MAE sebesar 2,3255 pada data *testing*. *Dropout rate* yang optimal dalam penelitian ini adalah 0,1, karena pada model LSTM ini menunjukkan performa terbaik dengan nilai RMSE sebesar 2,8521 dan

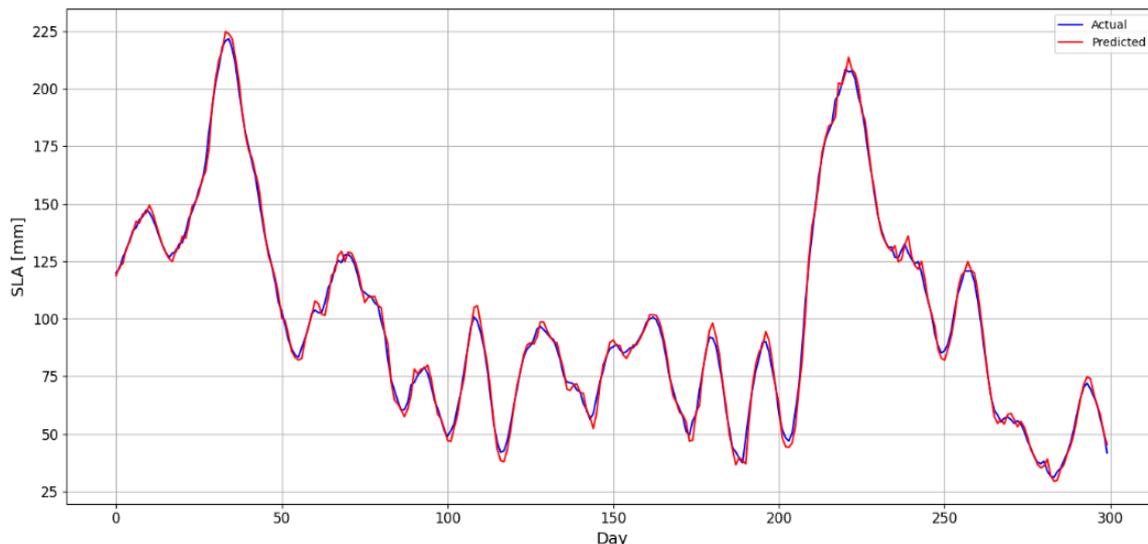
MAE sebesar 2,2241. Dengan demikian, hasil evaluasi *hyperparameter* menunjukkan bahwa kombinasi 2 *hidden layers*, 100 *hidden units*, 100 *epochs*, dan *dropout rate* 0,1, merupakan konfigurasi yang paling optimal untuk mencapai akurasi prediksi terbaik pada *dataset* SLA.

**Evaluasi Kinerja Model**

Kombinasi *hyperparameter* pada hasil pengujian sebelumnya memberikan gambaran yang lebih lengkap tentang kualitas prediksi model, sehingga memungkinkan evaluasi kinerja model LSTM. Pada pelatihan menggunakan model LSTM, *metric loss* yang digunakan pada *training* dan *validation loss* adalah MSE (*Mean Squared Error*). MSE umum digunakan dalam pelatihan model LSTM karena merupakan metrik umum dalam statistik yang digunakan untuk mengukur seberapa baik model prediksi dalam memperkirakan nilai sebenarnya. Evaluasi yang digunakan dalam penelitian ini adalah nilai RMSE, MAE, dan MAPE. Dengan menggunakan ketiga evaluasi performa model ini, pemahaman yang lebih baik tentang seberapa baik model LSTM dalam memprediksi data SLA dapat diperoleh. Hasil prediksinya dapat dilihat pada Gambar 7, di mana hasilnya berupa perbandingan antara data aktual dan prediksi pada 300 data *testing* pertama.



**Gambar 6.** Evaluasi *hyperparameter* Model LSTM Menggunakan *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) Untuk Menguji (a) *Hidden layer*, (b) *Hidden Units*, (c) *Epochs* dan (d) *Dropout Rate* Pada Data *Testing*



**Gambar 7.** Hasil Prediksi Model LSTM Pada 300 Data Pertama Data *Testing*

Hasil prediksi model LSTM ditunjukkan dalam Gambar 7, di evaluasi menggunakan MAE, RMSE, dan MAPE. Model ini, yang dioptimalkan menggunakan 2 *hidden layers*, 100 *hidden units*, 100 *epochs* dan *dropout rate* 0,1, menghasilkan nilai MAE 2,3776, RMSE 3,0389, dan MAPE 17% pada data *testing*. Nilai-nilai ini menunjukkan tingkat *error* yang kecil, menandakan akurasi prediksi yang tinggi dan keandalan model LSTM dalam mendekati nilai aktual SLA. Model LSTM juga telah terbukti lebih optimal dibandingkan dengan RNN konvensional dan metode *deep learning* lainnya seperti ANN, DNN dan CNN, seperti yang didukung oleh penelitian Premunendar *et al.* (2022). Penggunaan data yang lebih banyak dalam pemodelan ini memungkinkan tren SLA yang lebih jelas teramati dan meningkatkan akurasi prediksi. Mengingat kenaikan permukaan laut akibat perubahan iklim global, pemodelan dan prediksi yang akurat menjadi semakin penting untuk memahami dan mengantisipasi dampaknya.

**KESIMPULAN**

Hasil analisis data pasang surut bulanan di perairan Jepara tahun 2022 menunjukkan tipe pasang surut campuran condong harian tunggal (*mixed tide prevailing diurnal*) dengan rentang nilai Formzahl  $1.5 < F \leq 3$  lebih dominan, di mana dalam sehari terjadi satu kali pasang dan satu kali surut. Fluktuasi muka air laut meliputi *Low Water Level* (LWL) antara 0,64-0,84 meter, *Mean Sea*

*Level* (MSL) antara 1,11-1,27 meter dan *High Water Level* (HWL) antara 1,66-3,66 meter, dengan Nilai HWL sebesar 3,66 meter pada 20 Mei 2022, pukul 09.00 UTC, menandakan banjir rob akibat *storm surge*, sedangkan nilai pasang surut lainnya pada bulan Mei berada dalam rentang normal. Analisis korelasi Pearson dan koefisien determinasi yang dilakukan, menunjukkan nilai korelasi Pearson dan koefisien determinasi sedikit lebih tinggi pada 4 titik pengamatan dibandingkan dengan 39 titik, baik untuk komponen NRT maupun DT. Dengan nilai korelasi Pearson sebesar 0,7212 menunjukkan hubungan linier positif yang kuat, yang berarti peningkatan SLA cenderung diikuti oleh peningkatan pasang surut. Selain itu, koefisien determinasi pada *dataset* ini mencapai 52,01%, menunjukkan bahwa 52,01% variasi dalam pasang surut dapat dijelaskan oleh SLA. Tren SLA dari tahun 1993 hingga 2023 menunjukkan kenaikan signifikan rata-rata 4,794 mm/tahun, dengan puncak tertinggi pada tahun 2022 dan kecenderungan utama menuju peningkatan dalam dua dekade terakhir. Evaluasi *hyperparameter* atau pengaturan *hyperparameter* untuk model LSTM mengungkapkan kombinasi terbaik terdiri dari 2 *hidden layers*, 100 *epochs*, 100 *hidden units* dan *dropout rate* 0,1 dengan hasil menunjukkan nilai MAE sebesar 2,3776, RMSE sebesar 3,0389, dan MAPE sebesar 17%, menandakan tingkat *error* yang kecil, yang menandakan bahwa model LSTM memiliki performa yang baik dalam memprediksi SLA.

Hasil evaluasi tersebut menunjukkan bahwa model LSTM ini dapat diandalkan untuk memprediksi kenaikan permukaan laut dengan akurat.

## DAFTAR PUSTAKA

- Adebisi, N., Balogun, A.L., Min, T.H. & Tella, A. 2021. Advances in estimating Sea Level Rise: A review of tide gauge, satellite altimetry and spatial data science approaches. *Ocean and Coastal Management*, 208: 1–15.
- Amansyah, I., Indra, J., Nurlaelasari, E. & Juwita, A.R. 2024. Prediksi Penjualan Kendaraan Menggunakan Regresi Linear: Studi Kasus pada Industri Otomotif di Indonesia. *Innovative: Journal Of Social Science Research*, 4(4): 1199–1216.
- Andnur, M.O., Widada, S. & Suryo, A.A.D. 2022. Analisis Kenaikan Muka Air Laut dan Penurunan Muka Tanah untuk Perencanaan Tinggi Lantai Bangunan di Pesisir Utara Kota Semarang. *Indonesian Journal of Oceanography*, 4(2): 56–60.
- Andriansyah, T., Jumarang, M.I. & Apriansyah. 2017. Kondisi Pasang Surut, Laju Arus dan Batimetri Sungai Peniti Kecamatan Segedong Kabupaten Mompawah. *Prisma Fisika*, 6(3): 228–234.
- Chollet, F. 2018. *Deep Learning With Python*, Manning Publications Co., Shelter Island, NY.
- Clark, P.U., Church, J.A., Gregory, J.M. & Payne, A.J. 2015. Recent Progress in Understanding and Projecting Regional and Global Mean Sea Level Change. *Current Climate Change Reports*, 1: 224–246.
- Fahrudin, Y.I., Kurniawan, R. & Wijaya, Y.A. 2024. Penerapan Algoritma Regresi Linear Pada Data Harga Cabai Rawit di Pasar Indihiang. *Jurnal Mahasiswa Teknik Informatika*, 8(2): 1614–1620.
- Han, M.H., Chang, Y.S. & Yoo, J. 2023. Deconstructing the causes of July sea level variability in the East Sea from 1994 to 2021. *Frontiers in Marine Science*, 10: 1–13.
- Handoko, E.Y., Yuwono & Ariani, R. 2019. Analisis Kenaikan Muka Air Laut Indonesia Tahun 1993–2018 Menggunakan Data Altimetri. *Geoid*, 15(1): 58–64.
- Hossain, R. & Timmer, D. 2021. Machine learning model optimization with hyper parameter tuning approach. *Global Journal of Computer Science and Technology*, 21(2): 7–13.
- Lee, Y.W., Tay, K.G. & Choy, Y.Y. 2018. Forecasting Electricity Consumption Using Time Series Model. *International Journal of Engineering & Technology*, 7(4.30): 218–223.
- Machali, I. 2021. Metode penelitian kuantitatif (panduan praktis merencanakan, melaksanakan, dan analisis dalam penelitian kuantitatif), Fakultas Ilmu Tarbiyah dan Keguruan Universitas Islam Negeri (UIN) Sunan Kalijaga Yogyakarta.
- Mujadida, Z., Setiyono, H., Handoyo, G., Hariyadi & Marwoto, J. 2021. Analisis Dinamika Permukaan Laut di Laut Jawa dengan Recurrent Neural Network Periode 1993 sampai 2019. *Indonesian Journal of Oceanography*, 3(1): 100–110.
- Nababan, B., Hadiani, S. & Natih, N.M.N. 2015. Dinamika Anomali Paras Laut Perairan Indonesia. *Jurnal Ilmu dan Teknologi Kelautan Tropis*, 7(1): 259–272.
- Nissa, N.K., Nugraha, Y., Finola, C.F., Ernesto, A., Kangrawan, J. I. & Suherman, A.L. 2020. Evaluasi Berbasis Data: Kebijakan Pembatasan Mobilitas Publik dalam Mitigasi Persebaran COVID-19 di Jakarta. *Jurnal Sistem Cerdas*, 3(2): 84–94.
- Nugraha, A. 2022. BRIN: Banjir Rob di Pantura Akibat Seruak Badai di Laut Jawa. Diakses pada 17 September 2024, dari <https://www.liputan6.com>.
- Pagi, C. & Pundissing, R. 2022. Pengaruh efisiensi modal kerja terhadap rentabilitas pada perusahaan daerah air minum (PDAM) kabupaten tana toraja tahun 2016–2020. *Fair Value: Jurnal Ilmiah Akuntansi dan Keuangan*, 4(10): 4453–4462.
- Pramunendar, R.A., Prabowo, D.P. & Megantara, R.A. 2022. Metode Recurrent Neural Network (RNN) dengan Arsitektur LSTM untuk Analisis Sentimen Opini Publik Terkait Vaksin COVID-19. *Jurnal Informatika Upgris*, 8(1): 42–45.
- Rosalina, L., Oktarina, R., Rahmiati & Saputra, I. 2023. *Buku Ajar Statistika*, CV. Muharika Rumah Ilmiah.
- Sihotang, D.G., Setiyono, H., Subardjo, P., Satriadi, A., Hariyadi, Widiaratih, R. & Rifai, A. 2020. Sedimentasi dan Abrasi di Pantai Bandengan, Kabupaten Jepara. *Indonesian Journal of Oceanography*, 2(4): 334–340.
- Sorkhabi, O. M., Shadmanfar, B. & Al-Amidi, M. M. 2023. Deep learning of sea-level variability and flood for coastal city resilience.

*City and Environment Interactions*, 17: 1–11.  
Supriadi, G. 2021. Statistik Penelitian Pendidikan,  
UNY Press.  
Syaifullah, M.D. 2015. Siklon Tropis, Karakteristik

dan Pengaruhnya di Wilayah Indonesia pada  
Tahun 2012. *Jurnal Sains & Teknologi  
Modifikasi Cuaca*, 16(2): 61–71.