



Implementasi Metode *Long Short-Term Memory* (LSTM) Dalam Peramalan Tinggi Gelombang Untuk Wilayah Perairan Kabupaten Bolaang Mongondow Utara Provinsi Sulawesi Utara

Juan C. Budiman^{#a}, Arthur H. Thambas^{#b}, Cindy J. Supit^{#c}

[#]Program Studi Teknik Sipil Universitas Sam Ratulangi, Manado, Indonesia

^ajuanbudiman03@gmail.com, ^barthur.thambas@unsrat.ac.id, ^ccindyjeanesupit@unsrat.ac.id

Abstrak

Gelombang laut merupakan fenomena alam yang dibangkitkan oleh angin dan memiliki peran penting dalam rekayasa pantai, perikanan, serta transportasi maritim. Informasi tinggi gelombang sangat diperlukan, namun sifat stokastik gelombang laut membuat prediksinya masih menjadi tantangan. Penelitian ini bertujuan mengembangkan model prakiraan tinggi gelombang signifikan menggunakan algoritma *Long Short-Term Memory* (LSTM) di perairan Kabupaten Bolaang Mongondow Utara, Sulawesi Utara. Dataset yang digunakan berasal dari ERA5 berupa tinggi gelombang signifikan ($H_{s(ERA5)}$), komponen angin zonal-meridional yang dikonversi menjadi $H_{s(wind)}$, serta data altimetri untuk validasi. Model LSTM dilatih pada data 1998–2021, divalidasi 2022, dan diuji 2023 dengan horizon prediksi 1 hari. Hasil menunjukkan bahwa model mampu memprediksi tinggi gelombang signifikan dengan baik. Evaluasi menggunakan data uji menghasilkan nilai kesalahan rendah, dengan RMSE dan MAE pada kisaran sentimeter. Validasi terhadap data altimetri memperlihatkan kinerja lebih baik pada $H_{s(ERA5)}$ (RMSE 0,282 m; MAE 0,235 m; MAPE 37,98%) dibanding $H_{s(wind)}$ (RMSE 0,460 m; MAE 0,434 m; MAPE 78,34%). Model juga berhasil merepresentasikan variabilitas musiman sesuai pola aktual. Hasil ini menunjukkan bahwa metode LSTM efektif untuk peramalan tinggi gelombang signifikan dan berpotensi mendukung sistem peringatan dini serta perencanaan wilayah pesisir di Indonesia.

Kata kunci: deep learning, LSTM, peramalan gelombang, ERA5, altimetri

1. Pendahuluan

1.1. Latar belakang

Kemampuan untuk memprediksi tinggi gelombang laut secara akurat sangat penting dalam pengelolaan wilayah pesisir dan peringatan dini bencana maritim. Metode prediksi tradisional seperti Derbyshire dan SMB (Sverdrup-Munk-Bretscheider) menggunakan pendekatan empiris berbasis rumus yang mempertimbangkan kecepatan angin, durasi, dan *fetch* untuk memperkirakan tinggi gelombang. Namun, metode ini memiliki keterbatasan dalam menangani data deret waktu yang kompleks, non-linier, serta kurang mampu menangkap dinamika sistem laut yang berubah secara spasial dan temporal.

Di sisi lain, kemajuan teknologi kecerdasan buatan telah memungkinkan pengembangan model prediksi yang lebih akurat dan adaptif. Salah satu pendekatan yang menjanjikan adalah *Long Short-Term Memory* (LSTM), yang merupakan varian dari *Recurrent Neural Network* (RNN). LSTM dirancang untuk mengingat hubungan jangka panjang dalam data deret waktu dan terbukti efektif untuk memodelkan sistem kompleks yang bergantung pada data historis, termasuk dalam bidang oseanografi dan atmosfer.

Berdasarkan hal tersebut, penelitian ini bertujuan untuk menerapkan metode LSTM dalam peramalan tinggi gelombang laut dan membandingkan hasil prediksinya dengan data observasi dari satelit altimetri sebagai validasi.

1.2. Rumusan Masalah

1. Bagaimana implementasi metode Long Short-Term Memory (LSTM) dalam peramalan tinggi gelombang laut di wilayah perairan Bolaang Mongondow Utara?
2. Bagaimana tingkat akurasi hasil prediksi tinggi gelombang laut yang dihasilkan oleh model LSTM jika dibandingkan dengan data observasi altimetri?
3. Sejauh mana model LSTM mampu merepresentasikan dinamika tinggi gelombang laut berdasarkan data historis dan data observasi satelit?

1.3. Batasan Penelitian

1. Data yang digunakan terbatas pada (i) reanalisis ERA5 SWH (swh), (ii) komponen angin u/v ERA5 untuk membentuk $H_{s(wind)}$, dan (iii) observasi satelit altimetri sebagai pembanding.
2. Penelitian difokuskan pada wilayah perairan Bolaang Mongondow Utara, Provinsi Sulawesi Utara.
3. Model LSTM yang dikembangkan hanya digunakan untuk prediksi tinggi gelombang dan tidak mencakup parameter oceanografi lainnya.
4. Validasi dilakukan hanya menggunakan data altimetri yang tersedia selama periode tertentu.

1.4. Tujuan Penelitian

1. Menerapkan metode Long Short-Term Memory (LSTM) untuk melakukan prediksi tinggi gelombang laut di wilayah perairan Bolaang Mongondow Utara.
2. Melakukan validasi hasil prediksi tinggi gelombang menggunakan data observasi satelit altimetri.
3. Menganalisis performa model LSTM dalam merepresentasikan kondisi aktual gelombang laut berdasarkan data historis dan data observasi.

1.5. Manfaat Penelitian

1. Memberikan alternatif metode prediksi tinggi gelombang laut berbasis kecerdasan buatan.
2. Mendukung sistem peringatan dini dan perencanaan wilayah pesisir.
3. Menyediakan informasi akurat bagi pelayaran dan kegiatan kelautan lainnya.

1.6. Lokasi Penelitian

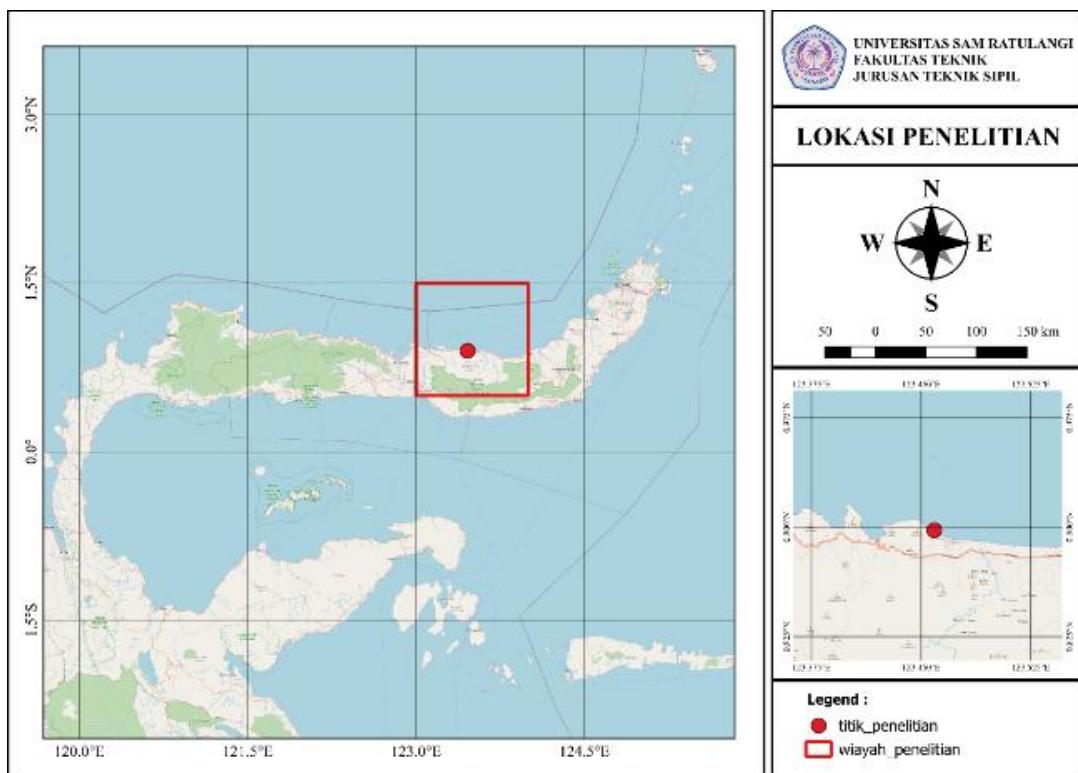
Penelitian ini dilakukan di wilayah perairan Bolaang Mongondow Utara, Provinsi Sulawesi Utara, Indonesia. Wilayah ini memiliki karakteristik kelautan yang dinamis dan relevan untuk kajian prediksi gelombang laut karena berada di kawasan yang rawan terhadap gelombang tinggi dan memiliki aktivitas perikanan serta pelayaran yang cukup tinggi. Koordinat umum wilayah penelitian berkisar antara $0,5^\circ$ hingga $1,5^\circ$ LU dan 123° hingga 124° BT.

2. Metode Penelitian

2.1. Lokasi Penelitian dan Pengumpulan Data

Wilayah penelitian berlokasi di perairan pesisir Bolaang Mongondow Utara, Provinsi Sulawesi Utara, Indonesia, dengan titik pusat penelitian pada koordinat sekitar 0.8978° LU dan 123.4590° BT. Lokasi ini mencakup pesisir Kecamatan Bintauna dan sekitarnya, yang menghadap langsung ke Laut Sulawesi.

Untuk keperluan prediksi tinggi gelombang signifikan, digunakan data komponen angin zonal (u_{10}) dan meridional (v_{10}), serta data tinggi gelombang signifikan (swh) dengan grid $0,5^\circ$ selama 1998–2023 yang bersumber dari reanalisis ERA5 ECMWF. Nilai pada koordinat studi ($0,8978^\circ$ LU, 123.4590° BT) diperoleh melalui interpolasi bilinear ke titik tersebut, kemudian diagregasi menjadi rerata harian. Sebagai data pembanding, digunakan data tinggi gelombang signifikan dari satelit altimetri yang diperoleh dari CMEMS, produk Level-3 SWH (variabel VAVH) untuk periode September–Desember 2023.



Gambar 1. Lokasi Penelitian
(Sumber: QGIS 3.40 dan Google Earth Pro)

2.2. Bagan Alir

Metode penelitian pada Tugas Akhir ini disusun ke dalam suatu bagan alir. Bagan alir tersebut dapat dilihat pada Gambar 2.

2.3. Pra-pemrosesan Data

2.3.1. Pengkonversian Komponen u_{10} dan v_{10}

Pembentukan tinggi gelombang signifikan (H_s) dari angin ($H_{s(wind)}$) menggunakan komponen angin 10 m ERA5 (u_{10} , v_{10}), Kecepatan angin (U_{10}) dihitung sebagai:

$$U_{10} = \sqrt{u_{10}^2 + v_{10}^2}$$

Arah angin dihitung sebagai arah datang dalam derajat

$$\theta = (\text{atan2}(-u_{10}, -v_{10}) \times 180/\pi + 360) \bmod 360$$

Nilai θ kemudian diklasifikasikan ke delapan sektor (N, NE, E, SE, S, SW, W, NW) menggunakan batas $22,5^\circ$ sebagai ambang antar-sektor. Untuk setiap sektor angin ditetapkan fetch efektif (F_{eff} (meter)) yang merepresentasikan jarak hembusan angin bebas-halangan menuju lokasi. Nilai F_{eff} ditentukan per sektor (berdasarkan geometri pantai setempat) dan dipetakan ke setiap waktu t sesuai sektor θ yang aktif. Dengan demikian, terbentuk deret F .

Tinggi gelombang signifikan harian berbasis angin, $H_{s(wind)}$, diperkirakan menggunakan bentuk Sverdrup–Munk–Bretschneider (SMB) untuk kondisi deep-water pada *fetch-limited growth*. Parameterisasi yang digunakan adalah

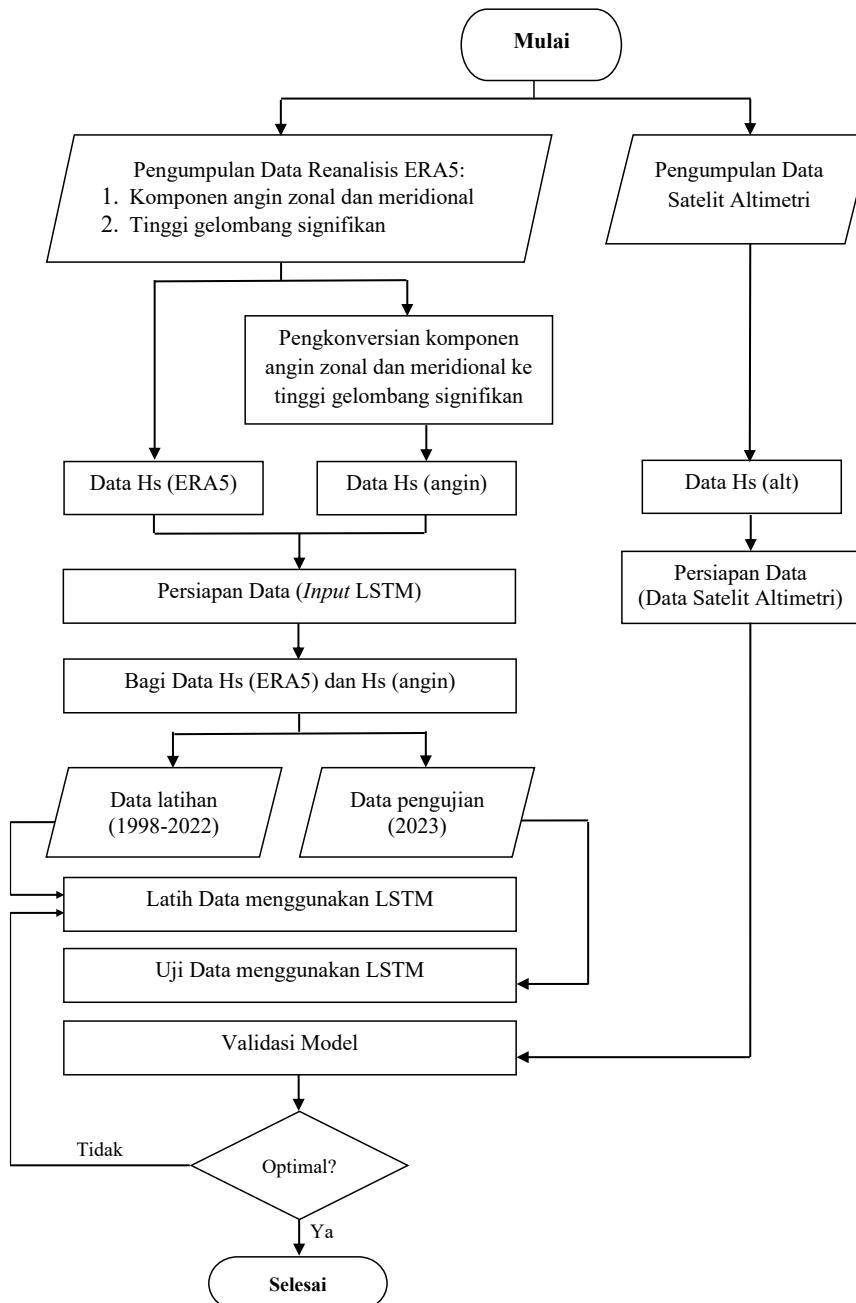
$$H_s = 0,0163U_{10}^2 \tanh \left[0,53 \left(\frac{gF}{U_{10}^2} \right)^{0,75} \right]$$

dengan $g = 9,81\text{m/s}^2$. Rumus ini menangkap dua rezim: (i) untuk fetch kecil, $H_{s(\text{wind})}$ meningkat tajam mengikuti pertumbuhan non-linier; (ii) untuk fetch besar, fungsi tanh (\cdot) membatasi (saturasi) pertumbuhan $H_{s(\text{wind})}$.

Deret $H_{s(\text{wind})}$ pada resolusi asli (jam-an/sub-harian) kemudian diagregasi menjadi rerata harian untuk memperoleh

$$\bar{H}_{s(\text{wind})(d)} = \frac{1}{N_d} \sum_{t \in d} H_{s(\text{wind})}$$

dengan d adalah tanggal dan N_d jumlah rekaman pada tanggal tersebut. Inilah yang digunakan sebagai $H_{s(\text{wind})}$ harian dalam pelatihan dan evaluasi model LSTM.



Gambar 2. Bagan Alir Penelitian

2.3.2. Penormalisasi Data

Proses normalisasi data diterapkan agar nilai-nilai yang besar tidak mendominasi nilai-nilai yang lebih kecil. Dalam penelitian ini digunakan metode normalisasi min-max dengan rentang antara 0 hingga 1. Persamaan normalisasi min-max disajikan pada rumus berikut.

$$Norm = \frac{x - \min(x)}{\max(x) - \min(x)}$$

dimana :

x = Nilai data asli

$\min(x)$ = Nilai data terkecil

$\max(x)$ = Nilai data terbesar

2.4. Pembangunan Model LSTM

Model *Long Short-Term Memory (LSTM)* yang digunakan dalam penelitian ini dibangun menggunakan kerangka kerja PyTorch dengan konfigurasi arsitektur yang terdiri dari 2 *hidden layers* berukuran 64 unit dan dropout sebesar 0,2. Model menerima input berupa deret waktu tinggi gelombang signifikan (Hs) harian dengan panjang jendela (*lookback*) selama 60 hari dan menghasilkan prediksi untuk 1 hari ke depan (horizon = 1).

Proses pelatihan menggunakan fungsi optimisasi Adam dengan laju pembelajaran awal sebesar 0,001. Batch size ditetapkan sebesar 32, dan model dilatih hingga 200 epoch dengan mekanisme *learning rate scheduler (ReduceLROnPlateau)* yang akan menurunkan laju pembelajaran sebesar 50% jika *validation loss* tidak mengalami perbaikan dalam 5 epoch berturut-turut. Seluruh data diubah menjadi resolusi harian melalui proses resampling dan interpolasi, kemudian dinormalisasi menggunakan Min-Max scaler yang di-fit hanya pada data latih untuk menghindari kebocoran data (data leakage). Dataset dibagi menjadi tiga bagian: data latih (≤ 2021), data validasi (2022), dan data uji (2023). Proses pelatihan dilakukan menggunakan data latih, sedangkan data validasi digunakan untuk memantau kinerja model selama proses pelatihan dan mencegah overfitting.

Arsitektur LSTM yang digunakan bersifat many-to-one, di mana setiap 60 hari data historis digunakan untuk memprediksi 1 nilai Hs pada hari berikutnya. LSTM dipilih karena kemampuannya mengingat ketergantungan jangka panjang dalam data deret waktu dan mengatasi masalah vanishing gradient yang sering muncul pada jaringan saraf berulang (Recurrent Neural Network, RNN) konvensional. Dengan demikian, model ini mampu mempelajari pola musiman maupun intramusiman pada gelombang laut yang dipengaruhi oleh fenomena atmosfer dan oseanografi.

2.5. Pengvalidasian Model

Untuk menilai tingkat akurasi dan kinerja model yang dikembangkan dalam memprediksi tinggi gelombang signifikan, digunakan tiga jenis metrik evaluasi, yaitu root mean square error (RMSE),

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

mean absolute error (MAE),

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

serta mean absolute percentage error (MAPE)

$$MAPE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Dimana:

y_i = Nilai sebenarnya

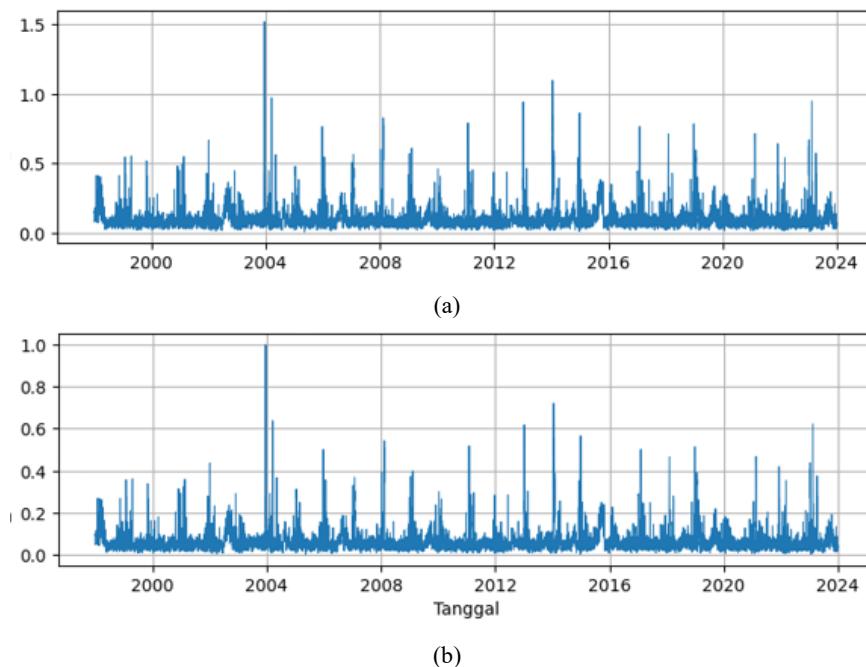
$$\begin{aligned}\hat{y}_i &= \text{Nilai prediksi} \\ n &= \text{Jumlah sampel}\end{aligned}$$

3. Hasil dan Pembahasan

3.1. Prapemrosesan Data

Sebelum membangun model LSTM, komponen angin u_{10} dan v_{10} dikonversi menjadi tinggi gelombang signifikan $H_{s(wind)}$ menggunakan parameterisasi Sverdrup–Munk–Bretschneider (SMB). Kemudian, data tersebut menjadi data masukan untuk pelatihan, validasi dan pengujian model LSTM menggunakan dataset angin ($H_{s(wind)}$).

Selanjutnya, kedua deret tinggi gelombang signifikan $H_{s(wind)}$ dan $H_{s(ERA5)}$ dinormalisasi dengan *min-max scaling* ke rentang (0, 1) untuk menstabilkan proses pelatihan LSTM. Normalisasi ini tidak mengubah pola temporal, hanya mengubah skala nilainya. Gambar 3 memperlihatkan data sebelum (a) dan sesudah normalisasi (b), dimana pola tetap serupa sementara rentang nilai terpetakan ke [0,1].



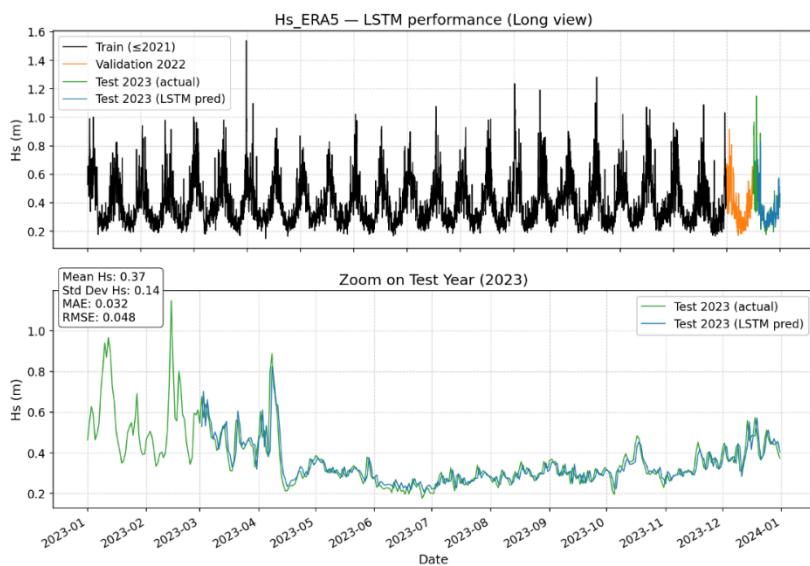
Gambar 3. Data sebelum (a) dan sesudah (b) dinormalisasi

3.2. Hasil Peramalan Tinggi Gelombang Signifikan

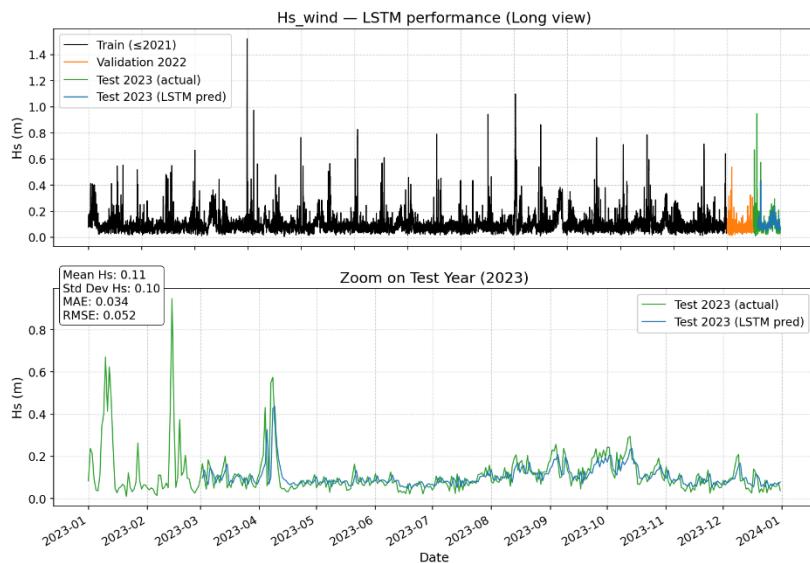
Setelah proses pelatihan model, tahap selanjutnya adalah melakukan prediksi tinggi gelombang signifikan (H_s) harian pada periode validasi (2022) dan uji (2023). Evaluasi dilakukan terhadap dua jenis data masukan $H_{s(ERA5)}$ dan $H_{s(wind)}$. Pemisahan dataset dilakukan dengan proporsi: data latih ≤ 2021 , data validasi = 2022, dan data uji = 2023.

Pelatihan model LSTM pada data $H_{s(ERA5)}$ menghasilkan nilai training loss akhir sebesar 0.00185 dan validation loss sebesar 0.00115, yang menunjukkan kemampuan model dalam mempelajari pola data pelatihan dan mempertahankannya pada data validasi dengan baik. Evaluasi pada data uji tahun 2023 memberikan nilai Mean Absolute Error (MAE) sebesar 0.032 m dan Root Mean Square Error (RMSE) sebesar 0.048 m, dengan rata-rata H_s sebesar 0.37 m dan standar deviasi 0.14 m.

Gambar 4 menampilkan perbandingan antara data pelatihan (hitam), data validasi tahun 2022 (orange), data uji aktual tahun 2023 (hijau), dan hasil prediksi LSTM (biru). Hasil prediksi LSTM menunjukkan kecenderungan yang selaras dengan tren data aktual, baik pada periode gelombang tinggi maupun rendah. Model mampu merepresentasikan fluktuasi intramusiman dan puncak musiman dengan cukup akurat, meskipun pada beberapa peristiwa ekstrem terdapat kecenderungan sedikit meremehkan amplitudo puncak.



Gambar 4. Grafik hasil peramalan $H_{s(ERAS5)}$ menggunakan LSTM



Gambar 5. Grafik hasil peramalan $H_{s(wind)}$ menggunakan LSTM

Dengan konfigurasi *hyperparameter* yang sama, pelatihan model LSTM pada data $H_{s(wind)}$ menghasilkan nilai *training loss* akhir sebesar 0.00148 dan *validation loss* sebesar 0.00094. Evaluasi pada data uji tahun 2023 memberikan nilai MAE sebesar 0.034 m dan RMSE sebesar 0.052 m, dengan rata-rata Hs sebesar 0.11 m dan standar deviasi 0.10 m.

Gambar 5 menunjukkan perbandingan antara data pelatihan (hitam), data validasi tahun 2022 (orange), data uji aktual tahun 2023 (hijau), dan hasil prediksi LSTM (biru). Prediksi yang dihasilkan untuk $H_{s(wind)}$ secara umum sejalan dengan pola yang tercatat pada data aktual. Namun, pada beberapa puncak gelombang ekstrem, amplitudo hasil prediksi tampak lebih rendah dibandingkan pengamatan. Perbedaan ini dapat disebabkan oleh sifat $H_{s(wind)}$ yang dihitung dari data angin permukaan, sehingga tidak mempertimbangkan kontribusi gelombang jauh (swell) maupun faktor oseanografi lain yang mempengaruhi kondisi gelombang di lokasi studi.

Analisis variabilitas musiman menunjukkan bahwa pola perubahan tinggi gelombang signifikan per musim monsun dapat direpresentasikan dengan baik oleh model LSTM pada kedua dataset. Pada dataset $H_{s(wind)}$, nilai rata-rata Hs tertinggi terjadi pada musim peralihan kedua (September–November) dengan 0.1291 m (aktual) dan 0.1238 m (prediksi), sedangkan nilai terendah terjadi pada musim barat laut (Desember–Februari) dengan 0.0790 m (aktual) dan 0.0850 m (prediksi). Pada dataset $H_{s(ERAS5)}$, nilai rata-rata Hs tertinggi terjadi pada musim tenggara

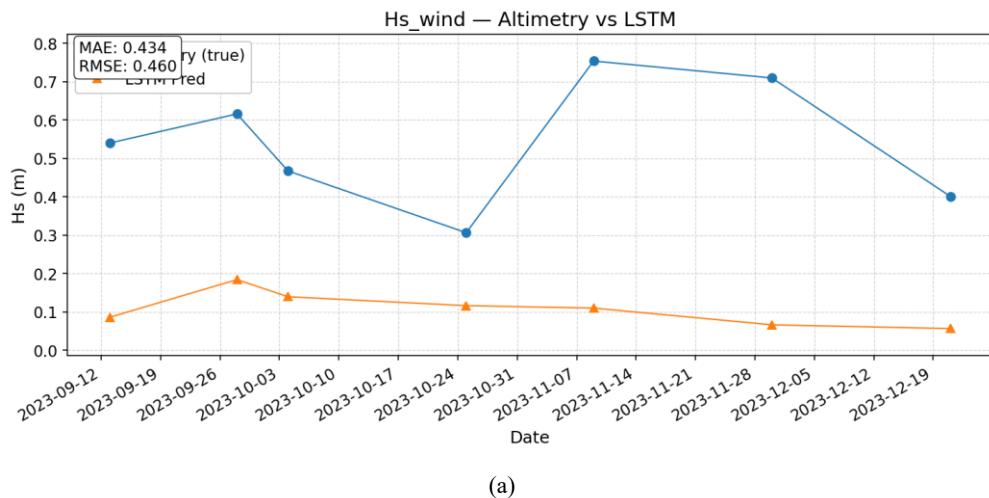
(Juni–Agustus) dengan 0.4957 m (aktual) dan 0.4962 m (prediksi), sedangkan nilai terendah terjadi pada musim peralihan pertama (Maret–Mei) dengan 0.3929 m (aktual) dan 0.3993 m (prediksi).

Tabel 1. Perbandingan Rata-Rata Musiman Tinggi Gelombang Signifikan

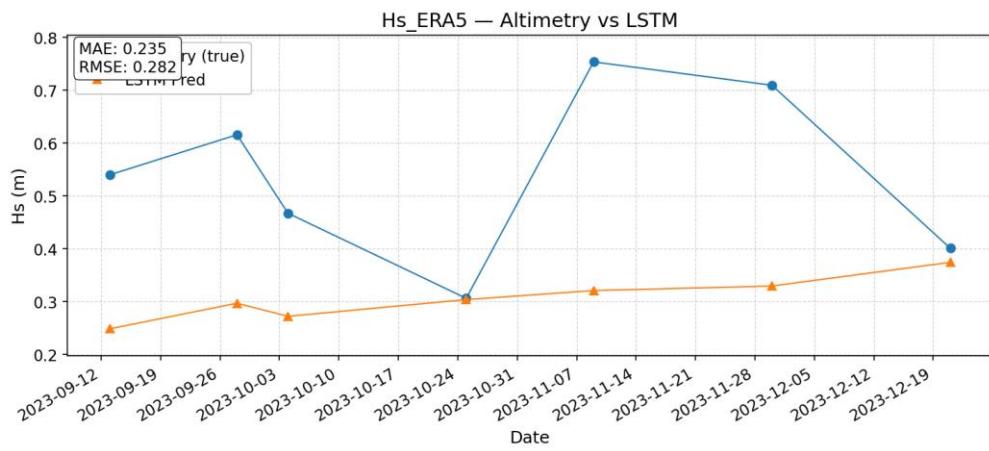
Musim	$H_{s(wind)}$ Aktual (m)	$H_{s(wind)}$ Prediksi (m)	$H_{s(ERA5)}$ Aktual (m)	$H_{s(ERA5)}$ Prediksi (m)
Musim Barat Laut (Des–Feb)	0.0790	0.0850	0.4257	0.4249
Peralihan Pertama (Mar–Mei)	0.1030	0.1032	0.3929	0.3993
Musim Tenggara (Jun–Agu)	0.0905	0.0922	0.2627	0.2671
Peralihan Kedua (Sep–Nov)	0.1291	0.1238	0.3203	0.3176

3.3. Validasi Model LSTM

Perbandingan antara hasil prediksi LSTM dan pengamatan tinggi gelombang signifikan dari satelit altimetri dilakukan untuk periode yang memiliki irisan waktu selama periode September – Desember 2023.



(a)



(b)

Gambar 6. Grafik Perbandingan Data Satelit Altimetri dengan Hasil Peramalan $H_{s(wind)}$
(a) dan $H_{s(ERA5)}$ (b) Menggunakan LSTM

Untuk $H_{s(wind)}$, model menunjukkan MAE sebesar 0.434 m dan RMSE sebesar 0.460 m. Nilai kesalahan ini relatif tinggi dibandingkan hasil validasi dengan $H_{s(ERA5)}$. Secara visual, perbedaan paling mencolok terlihat pada amplitudo puncak gelombang, di mana prediksi $H_{s(wind)}$ cenderung underestimate terhadap data altimetri. Salah satu penyebab utama perbedaan ini adalah sifat $H_{s(wind)}$ yang hanya dihitung dari data angin permukaan, sehingga hanya merepresentasikan gelombang lokal (wind sea) dan mengabaikan kontribusi gelombang jarak jauh (swell). Selain itu, resolusi spasial data angin dan asumsi metode konversi ke H_s dapat menyebabkan ketidakakuratan dalam menangkap variasi skala kecil yang mungkin terdeteksi oleh altimetri. Faktor oceanografi seperti arus laut, topografi dasar laut, dan kondisi perairan terlokalisasi di sekitar titik studi juga dapat menyebabkan perbedaan antara hasil prediksi dan pengamatan altimetri.

Sebaliknya, untuk $H_{s(ERA5)}$, model menghasilkan MAE sebesar 0.235 m dan RMSE sebesar 0.282 m, yang menunjukkan kesesuaian yang lebih baik dengan data altimetri. Perbedaan yang lebih kecil ini disebabkan oleh karakteristik $H_{s(ERA5)}$ sebagai data hasil reanalisis yang menggabungkan informasi atmosfer, gelombang, dan interaksi laut-atmosfer, sehingga representasi kondisi gelombang lebih realistik dan mendekati hasil pengamatan altimetri.

Secara umum, hasil validasi ini mengindikasikan bahwa model LSTM yang dilatih dengan $H_{s(ERA5)}$ memiliki akurasi lebih tinggi dalam mereplikasi pola gelombang aktual yang diukur oleh altimetri dibandingkan dengan model yang dilatih menggunakan $H_{s(wind)}$. Namun, $H_{s(wind)}$ tetap memiliki nilai praktis dalam situasi operasional ketika data reanalisis atau observasi gelombang tidak tersedia, meskipun akurasinya lebih rendah dan cenderung menghasilkan deviasi yang lebih besar terhadap data satelit altimetri.

Selanjutnya, performa model LSTM dievaluasi menggunakan metrik RMSE, MAE, dan MAPE. Pengujian dilakukan pada dua dataset utama, yaitu $H_{s(wind)}$ dan $H_{s(ERA5)}$, dengan periode prediksi (Length of Output) yang bervariasi: 12 bulan, 6 bulan, 3 bulan, 1 bulan, dan 1 minggu. Evaluasi ini bertujuan untuk mengetahui pengaruh panjang jendela prediksi terhadap akurasi model. Nilai RMSE dan MAE yang rendah menunjukkan prediksi tinggi gelombang signifikan yang presisi, sedangkan MAPE memberikan gambaran kesalahan relatif dalam persen.

Berdasarkan hasil validasi internal, nilai RMSE dan MAE umumnya lebih kecil pada prediksi jangka pendek (1 minggu) dibanding prediksi jangka panjang (12 bulan), baik untuk $H_{s(wind)}$ maupun $H_{s(ERA5)}$. MAPE untuk kedua dataset juga relatif rendah (<3%) pada semua skenario Length of Output, yang menunjukkan bahwa model mampu memprediksi pola gelombang dengan kesalahan relatif yang kecil.

Tabel 2. Validasi Model LSTM

Input Data	Length of Output	Validation Data	RMSE	MAE	MAPE
$H_{s(wind)}$	12 bulan	$H_{s(wind)}$ prediksi	0.0065	0.0042	2.388
$H_{s(ERA5)}$	12 bulan	$H_{s(ERA5)}$ prediksi	0.0237	0.0068	1.870
$H_{s(wind)}$	6 bulan	$H_{s(wind)}$ prediksi	0.0062	0.0040	2.413
$H_{s(ERA5)}$	6 bulan	$H_{s(ERA5)}$ prediksi	0.0311	0.0070	2.362
$H_{s(wind)}$	3 bulan	$H_{s(wind)}$ prediksi	0.0064	0.0041	2.246
$H_{s(ERA5)}$	3 bulan	$H_{s(ERA5)}$ prediksi	0.0097	0.0040	1.768
$H_{s(wind)}$	1 bulan	$H_{s(wind)}$ prediksi	0.0071	0.0045	2.172
$H_{s(ERA5)}$	1 bulan	$H_{s(ERA5)}$ prediksi	0.0088	0.0063	1.622
$H_{s(wind)}$	1 minggu	$H_{s(wind)}$ prediksi	0.0056	0.0033	1.826
$H_{s(ERA5)}$	1 minggu	$H_{s(ERA5)}$ prediksi	0.0095	0.0071	2.052
Hs_Altimetry		$H_{s(wind)}$ prediksi	0.460	0.434	78.34
Hs_Altimetry		$H_{s(ERA5)}$ prediksi	0.282	0.235	37.98

Validasi terhadap data altimetri memperlihatkan perbedaan performa yang cukup besar antara kedua sumber data input. Model berbasis $H_{s(ERA5)}$ menunjukkan nilai RMSE (0.282 m), MAE (0.235 m), dan MAPE (37.98%) yang lebih baik dibanding model berbasis $H_{s(wind)}$ dengan RMSE

(0.460 m), MAE (0.434 m), dan MAPE (78.34%). Secara keseluruhan, penerapan model LSTM dalam memprediksi tinggi gelombang signifikan memberikan hasil yang baik, meskipun hasilnya dapat dipengaruhi oleh sejumlah faktor seperti kualitas data input dan asumsi yang digunakan dalam model. Selain itu, perbandingan dengan data altimetri menunjukkan tingkat kesesuaian yang baik, di mana model berbasis data $H_{s(ERA5)}$ memberikan tingkat akurasi tertinggi.

4. Kesimpulan

Berdasarkan hasil penelitian mengenai implementasi metode Long Short-Term Memory (LSTM) dalam peramalan tinggi gelombang signifikan di wilayah perairan Kabupaten Bolaang Mongondow Utara menggunakan dua sumber data ($H_{s(wind)}$ dan $H_{s(ERA5)}$), diperoleh beberapa kesimpulan sebagai berikut:

1. Penerapan metode LSTM dalam peramalan tinggi gelombang laut di perairan Bolaang Mongondow Utara berhasil dilakukan dengan baik. Model dibangun menggunakan data historis $H_{s(wind)}$ dan $H_{s(ERA5)}$, serta menghasilkan prediksi jangka pendek hingga jangka menengah dengan performa stabil, ditandai dengan nilai RMSE dan MAE yang rendah serta $MAPE < 3\%$ pada semua skenario, dengan akurasi tertinggi pada prediksi jangka pendek (1 minggu), baik untuk $H_{s(wind)}$ (RMSE = 0.0056 m; MAPE = 1.826%) maupun $H_{s(ERA5)}$ (RMSE = 0.0095 m; MAPE = 2.052%). Nilai error yang rendah menunjukkan bahwa LSTM mampu mempelajari pola temporal gelombang laut secara efektif.
2. Hasil validasi terhadap data observasi satelit altimetri memperlihatkan bahwa model berbasis $H_{s(ERA5)}$ memiliki akurasi lebih tinggi dibanding $H_{s(wind)}$, dengan nilai RMSE = 0.282 m, MAE = 0.235 m, dan MAPE = 37.98%. Sementara itu, model berbasis $H_{s(wind)}$ menghasilkan RMSE = 0.460 m, MAE = 0.434 m, dan MAPE = 78.34%. Hal ini menunjukkan bahwa integrasi parameter atmosfer dan oseanografi dalam $H_{s(ERA5)}$ membuat prediksi LSTM lebih konsisten dengan hasil observasi.
3. Model LSTM mampu merepresentasikan dinamika gelombang laut, termasuk variabilitas musiman. Hasil prediksi menunjukkan pola musiman yang sesuai dengan data aktual, seperti puncak gelombang pada musim peralihan kedua ($H_{s(wind)}$) dan musim barat laut ($H_{s(ERA5)}$). Hal ini menegaskan bahwa LSTM efektif dalam menggambarkan perubahan temporal gelombang laut berdasarkan data historis maupun validasi satelit altimetri.

Referensi

- S. Fan, N. Xiao, and S. Dong, “A novel model to predict significant wave height based on Long Short-Term Memory network,” *Ocean Eng.*, vol. 205, Jun. 2020.
- P. Purwanto, R. Tristanto, G. Handoyo, M. Trenggono, and A. A. D. Suryoputro, “Analisis Peramalan dan Periode Ulang Gelombang di Perairan Bagian Timur Pulau Lirang, Maluku Barat Daya,” *Indonesian Journal of Oceanography*, vol. 2, no. 1, pp. 80-89, Mar. 2020.
- H. Yoon, S. C. Jun, Y. Hyun, G. O. Bae, K. K. Lee, “A comparative study of artificial neural networks and support vector machines for predicting ground water levels in a coastal aquifer,” *J. Hydrol.*, vol. 396, pp. 128-138, 2011
- H. A. A. Guner, Y. Yuksel, and E. O. Cevik, “Estimation of wave parameters based on nearshore wind-wave correlations,” *Ocean Eng.*, vol. 63, pp 52-62, 2013.
- W. Wang, R. Tang, C. Li, P. Liu, L. Luo, “A BP neural network model optimized by Mind Evolutionary Algorithm for predicting the ocean wave heights,” *Ocean Eng.*, vol. 162, pp. 98-107, 2018.
- M. Rizki, S. Basuki, and Y. Azhar, “Implementasi Deep Learning Menggunakan Arsitektur Long-Short Term Memory untuk Prediksi Curah Hujan Kota Malang,” *Repositor*, vol. 2, no. 3, pp. 331-338, 2020.
- F. C. Minuzzi and L. Farina, “A deep learning approach to predict significant wave height using long short-term memory,” *Ocean Modelling*, vol. 181, 2023
- Aisjah, A. S., Arifin, S., & Danistha, W. (2016). Sverdrup Munk Bretschneider Modification (SMB) for Significant Wave Height Prediction in Java Sea. *British Journal of Applied Science and Technology*, 16(2), 1–8.
- Babanin, A., & Young, I. (2020). *Ocean wave dynamics*. World Scientific Publishing.
- Chandramohan, P., Ramanamurthy, M. V., Joseph, K. J., Alluri, S. R., Varthini, D. S., & Navaneeth, K. N. (2018). Origin, transformation and measurement of waves in ocean. In *Coastal Reservoir Technology and Applications* (pp. 59–74). Springer.
- Darbyshire, J. (1957). A note on the comparison of proposed wave spectrum formulae. *Deutsche Hydrographische Zeitschrift*, 10, 184–190.

- Hang-Sun, C. (1980). A review on the characteristics and description of ocean waves. *Bulletin of the Society of Naval Architects of Korea*, 17, 43–47.
- Irani, G., Gotwols, B., & Bjerkaas, A. W. (1986). The 1978 Ocean Wave Dynamics Experiment. In *Ocean surface wave dynamics* (pp. 165–179). Springer.
- Mei, C. C. (1983). *The applied dynamics of ocean surface waves*. World Scientific.
- Pierson, W. (1959). A study of wave forecasting methods and of the height of a fully developed sea on the basis of some wave records obtained by the O.W.S. Weather Explorer during a storm at sea. *Deutsche Hydrographische Zeitschrift*, 12, 244–259.
- Pushpam, M. M. P., & Enigo, F. S. (2020). Forecasting Significant Wave Height using RNN-LSTM Models. *2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)*, 1141–1146.
- Kagemoto, H. (2020). Forecasting a water-surface wave train with artificial intelligence – A case study. *Ocean Engineering*, 207, 107380.
- Dogan, G., Ford, M., & James, S. (2021). Predicting ocean-wave conditions using buoy data supplied to a hybrid RNN-LSTM neural network and machine learning models. *2021 IEEE International Conference on Machine Learning and Applied Network Technologies (ICMLANT)*, 1–6.
- Kusumawati, S. D. (2001). Analisis distribusi probabilitas gelombang laut.
- Mayasari, D. (2001). Analisis spektrum gelombang laut.
- Tindaon, G. P., Djamaruddin, R., Manengkey, H. W. K., & Ngangi, E. L. (2022). Karakteristik arah dan tinggi gelombang signifikan di Laut Sulawesi. *Jurnal Pesisir dan Laut Tropis*.
- Pramita, A. W., Sugianto, D., Prasetyawan, I., Kurniawan, R., & Praja, A. S. (2020). Pola tinggi gelombang di Laut Jawa menggunakan model Wavewatch-III.
- Triwulan, Y., Hariyanto, N., & Anwari, S. (2013). Peramalan beban puncak listrik jangka pendek menggunakan metode jaringan syaraf tiruan.
- Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2015). Recurrent neural networks.
- Talita, A. S., & Wiguna, A. (2019). Implementasi algoritma Long Short-Term Memory (LSTM) untuk mendeteksi ujaran kebencian pada kasus Pilpres 2019. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*.
- Sonya, W. A. (2017). Perancangan sistem prediktor ketinggian gelombang berbasis Thiessen Polygon dan jaringan saraf tiruan di perairan dangkal Jawa Timur.
- Nabila, N. M., Sasmito, B., & Sukmono, A. (2019). Studi karakteristik gelombang perairan Laut Jawa menggunakan satelit altimetri tahun 2016–2018.
- Supriyadi, E. (2019). Pemanfaatan satelit altimetri untuk verifikasi tinggi gelombang signifikan Ocean Forecast System (OFS) – Model BMKG. *Jurnal Meteorologi dan Geofisika*.
- Gao, S., Huang, J., Li, Y., Liu, G., Bi, F., & Bai, Z. (2021). A forecasting model for wave heights based on a Long Short-Term Memory neural network. *Acta Oceanologica Sinica*, 40, 62–69.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., et al. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999–2049.
- Rumsarwir, J. M., Mamoto, J. D., & Tangkudung, N. J. A. (2023). Model distribusi kecepatan angin untuk peramalan gelombang menggunakan metode Derbyshire dan SPM di Sindulang Kecamatan Tumiting Kota Manado Sulawesi Utara. *TEKNO*, 21(86), 1992–2000.
- Thambas, A. H., Yuwono N. (2003). Model distribusi kecepatan angin dan pemanfaatannya dalam peramalan gelombang di wilayah tengah Indonesia (Pulau Jawa, Sulawesi, dan Kalimantan). *Universitas Gadjah Mada Yogyakarta*