

Prediksi Tinggi Gelombang Laut di Perairan Semarang – Demak dengan Menggunakan *Random Forest* dan *XGBoost*

Ganis Erutjahjo¹, Aji Supriyanto²

^{1,2}Program Studi Magister Teknologi Informasi, Universitas Stikubank, 50249, Semarang, Indonesia

Info Artikel

Riwayat Artikel:

Received 2025-07-17

Revised 2025-08-03

Accepted 2025-08-04

Corresponding Author:

Aji Supriyanto

Email: ajisup@edu.unisbank.ac.id



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstract – English Climate change and regional oceanographic activities have contributed to increasing significant wave height (SWH) and sea level rise (SLR) along the northern coast of Central Java (Semarang-Demak). This study aims to analyze and predict SWH and SLR using two artificial intelligence methods: Random Forest (RF) and Extreme Gradient Boosting (XGBoost). The dataset includes meteorological and oceanographic parameters from 2019 to 2024. Model performance was evaluated using accuracy metrics such as RMSE, MAE, MAPE, and the coefficient of determination (R^2). The results show that XGBoost outperforms RF in predicting both target variables. XGBoost achieved R^2 values of 0.9989 for SWH and 0.9921 for SLR, with MAPE scores of 1.6% and 1.1%, respectively. The most influential factor for SWH prediction was the historical significant wave height (hs), while the average daily sea level elevation had the highest impact on SLR prediction. Comparison plots between actual and predicted values indicate that both models effectively captured seasonal trends, particularly in identifying wave peaks in early months and sea level increases during mid-year. The 2025 forecast suggests rising SWH patterns from January to March and peak SLR values around June. These findings are expected to support coastal adaptation policies in response to climate change and to inform the design of more resilient marine infrastructure in the future.

Keywords : Prediction, Random Forest, Sea Level Rise (SLR), Significant Wave Height (SWH), XGBoost

Abstrak – Perubahan iklim dan aktivitas oseanografis regional telah berkontribusi terhadap peningkatan tinggi gelombang signifikan (SWH) dan kenaikan muka air laut (SLR) di wilayah pesisir utara Jawa Tengah (Semarang-Demak). Penelitian ini bertujuan untuk menganalisis dan memprediksi nilai SWH dan SLR dengan menggunakan dua metode kecerdasan buatan, yaitu Random Forest (RF) dan Extreme Gradient Boosting (XGBoost). Data yang digunakan meliputi parameter meteorologi dan oseanografi periode 2019–2024. Evaluasi performa model dilakukan dengan pengukuran akurasi seperti RMSE, MAE, MAPE, dan koefisien determinasi (R^2). Hasil analisis menunjukkan bahwa XGBoost memberikan performa prediksi yang lebih baik dibandingkan RF untuk kedua variabel target. Model XGBoost mampu mencapai R^2 sebesar 0.9989 dalam prediksi SWH dan 0.9921 dalam prediksi SLR, dengan nilai MAPE masing-masing sebesar 1.6% dan 1.1%. Faktor paling berpengaruh terhadap SWH adalah tinggi gelombang signifikan historis (hs), sedangkan terhadap SLR adalah rata-rata harian elevasi muka laut. Grafik perbandingan aktual dan prediksi menunjukkan bahwa kedua model mengikuti pola tren musiman dengan baik, khususnya dalam mengidentifikasi puncak gelombang di awal tahun dan peningkatan muka laut pada pertengahan tahun. Prediksi untuk tahun 2025 mengindikasikan pola SWH yang cenderung meningkat pada bulan Januari–Maret, serta SLR yang mencapai puncak pada bulan Juni. Hasil ini diharapkan dapat mendukung pengambilan kebijakan adaptasi wilayah pesisir terhadap dampak perubahan iklim dan perencanaan infrastruktur kelautan yang lebih tangguh di masa mendatang.

Keywords: Kenaikan Muka Laut (SLR), Prediksi, Random Forest, Tinggi Gelombang Signifikan (SWH), XGBoost.

I. PENDAHULUAN

Indonesia merupakan salah satu negara kepulauan yang memiliki tantangan tersendiri terutama dalam pengelolaan wilayah pesisir. Diantaranya adalah pesisir utara Jawa seperti Kota Semarang dan Kecamatan Sayung Kabupaten Demak Jawa Tengah. Kedua wilayah ini berdampingan dengan dataran rendah berupa pantai atau pesisir yang sering terjadi bencana banjir rob. Menurut laporan *Environmental Protection Agency* (EPA) Tahun 2024, masalah kenaikan muka air laut (*Sea Level Rise* /SLR) dapat disebabkan perubahan iklim dan kenaikan gelombang laut yang mengakibatkan terjadinya pengurangan lahan pantai dan banjir rob daerah pesisir. Berdasarkan laporan situs resmi pemerintah Jawa Tengah (<https://jatengprov.go.id/>) tanggal 25 Juni 2025, bahwa genangan rob tidak hanya merambah pemukiman warga di pesisir pantai, tapi juga sudah meluap sampai ke jalan raya Semarang – Demak hingga ketinggian 50 cm yang sering menimbulkan kemacetan lalu lintas yang parah. Belum lagi karena dampak cuaca yang fluktuatif dapat menimbulkan bencana hidrometeorologi di Pantai Utara Jawa Tengah[1].

Kota Semarang memiliki panjang pantai 25 Km yang meliputi 4 kecamatan yaitu KecamatanTugu, Kecamatan Semarang Barat, Kecamatan Semarang Utara dan Kecamatan Genuk[2]. Sedangkan Kecamatan Sayung memiliki garis pantai sepanjang 20,9 Km[3]. Ancaman kerusakan alam di wilayah pesisir Kota Semarang diantaranya karena abrasi dan akresi. Abrasi dan akresi yang cukup signifikan dari tahun 2015 sampai dengan tahun 2021 di desa pesisir dengan panjang pantai 20,9 km yang telah mengalami abrasi pantai seluas 122,14 Ha dan akresi seluas 17,53 Ha dengan persentase abrasi (86%) dan akresi (14%). Laju abrasi secara keseluruhan (17,44 Ha/tahun) dan akresi (2,50 Ha/tahun). Daerah banjir pasang yang terjadi di wilayah pesisir mengakibatkan perubahan wilayah tersebut tererosi atau terjadi kenaikan muka air laut[3]. Sehingga menurut laporan Dinas Kelautan dan Perikanan(DKP) Jawa Tengah Tahun 2024, Luas pantai Semarang mundur hingga 2 Km, dan Demak mundur hingga 5 Km akibat abrasi.

Laut utara Jawa Tengah selain terjadi SLR juga penurunan tanah pantai. Terjadinya SLR global telah meningkatkan besaran HEX di dekat pantai Jawa sebesar 0,7m–0,8m selama tahun 2010–2017, yang sebanding dengan kenaikan muka air laut musiman[4]. Rata-rata laut Jawa secara umum mengalami SLR sebesar 3,9 mm per tahun[5]. Terjadinya SLR global telah meningkatkan besaran ketinggian ekstrem permukaan laut(Height Extremes/HEX) di dekat pantai Jawa sebesar 0,7m–0,8m selama tahun 2010–2017, yang sebanding dengan kenaikan muka air laut musiman[4]. Rata-rata laut Jawa secara umum mengalami SLR sebesar 3,9 mm per tahun[4]. Ini termasuk di wilayah laut Semarang dan Demak. Kenaikan di perairan Semarang sebesar +5,52 mm/tahun yang digunakan sebagai validasi dengan data pasang surut Semarang. Rata rata perubahan garis pantai di wilayah Demak sebesar -119,08 m, dan abrasi paling besar terjadi di Kecamatan Sayung sebesar -691 m[6]. Faktor utama yang menyebabkannya adalah SLR dipicu oleh beberapa unsur utama seperti gravitasi bulan dan matahari, serta tinggi gelombang laut (*Significant Wave Height /SWH*) terutama akibat cuaca buruk. Dampak perubahan iklim di Provinsi Jawa Tengah berupa genangan pasang surut(rob) yang mengganggu kegiatan industri, infrastruktur, permukiman, dan perikanan, bahkan beberapa desa tenggelam karena terjangan gelombang pasang[7]. Fenomena kenaikan air laut dan penurunan tanah telah terjadi di pesisir pantai Jawa Tengah terutama Semarang, Pekalongan, Demak[8][9][10][11], hal ini sebagai penyebab utama bencana hidrometeorologi yaitu banjir rob pada daerah tersebut[1][9][10]. Hal ini tentunya perlu dilakukan tindakan lebih lanjut dari para stakeholder untuk mitigasi bencana hidrometeorologi pesisir Semarang- Demak yang lebih parah. Salah satu solusinya adalah dengan melakukan prediksi tinggi gelombang laut (SWH) secara akurat.

Disisi lain kejadian SLR termasuk SWH dapat diprediksi dengan menggunakan algoritma kecerdasan buatan (*Artificial Intelligence /AI*) dengan *Machine Learning* (ML)[12][13]. Model ML dengan algoritma *Random Forest*(RF) dan *Extreme Gradient Boosting*(XGBoost) telah menunjukkan kinerja yang baik dalam memodelkan hubungan kompleks antara variabel input dan output[12]. Penelitian Dhiya'ulhaq menggunakan LSTM dan XGBoost untuk memprediksi tinggi gelombang di Kabupaten Tuban, XGBoost memberikan prediksi yang akurat dengan RMSE=0.143, ini dan menghasilkan error 63,4% lebih rendah dibanding LSTM, membantu meningkatkan keselamatan nelayan[14]. Penelitian Musbikhin tentang sensor pengukur gelombang pasang air laut di Pelabuhan Tanjung Mas Semarang, menggunakan satu variabel data dan satu metode matematika yaitu data rata-rata ketinggian tempat per bulan pada periode tertentu mengalami nilai akurasi yang kurang baik(66,0%)[15]. Oleh karena itu Tarwidi mengembangkan model XGBoost yang dioptimalkan untuk memprediksi run-up gelombang pada pantai miring, hasilnya menunjukkan akurasi tinggi dengan FRMSE paling kecil (0.054), dan R^2 tertinggi (0.974) dibandingkan metode lain seperti *Support Vector Regression* (SVR), *Random Forest*, dan *Multiple Linear Regression* (MLR)[16].


Penelitian Durap XGBoost adalah metode paling akurat dan konsisten untuk prediksi tinggi gelombang signifikan (SWH) dengan RMSE : 0.21 dan R^2 : 0.96 mengungguli metode lain seperti SVR, RF, dan MLR. Sementara SVR dan MLP juga cukup kompetitif, model linier seperti MLR terbukti tidak cukup dalam menangani dinamika kompleks laut[17]. Pada sisi lain *Random Forest* (RF) memiliki RMSE yang lebih baik (14.2%) dibanding Gboosting (15.7%)[18]. Namun RF prediksi periode gelombang lebih jelek dibanding *Artificial Neural Network*(ANN)[19]. Menurut Anggaraeni, metode ensemble learning seperti AdaBoost dan XGBoost dapat meningkatkan akurasi prediksi tinggi gelombang di Indoensia, yang penting untuk keselamatan maritim dan perencanaan pesisir[20]. Sebelumnya Callens melakukan prediksi Gelombang laut (signifikasi tinggi, periode pucak, arah dan kecepatan angin) selama 10 tahun dengan perbandingan algoritma RF dengan Gradient Boosted Trees (GBT), dimana GBT cenderung memiliki akurasi dan stabilisasi lebih baik[18]. Selanjutnya Kim mengembangkan model perbandingan antara XGBoost dengan RF untuk memperkirakan SWH pantai dengan untuk mitigasi banjir pantai. Hasilnya XGBoost performasnya lebih baik dengan R^2 : 0.85 dan RMSE : 0.18[21]. Sedangkan Leng memprediksi SWH dengan membandingkan XGBoost, CNN, SVR, dan regresi ridge (RR), hasilnya XGBoost memiliki prediksi paling akurat[22].

Bedasarkan referensi tersebut terlihat model XGBoost dan RF banyak digunakan karena memiliki akurasi tinggi dan error yang rendah. Namun model tersebut belum pernah diterapkan pada SWH di Semarang- Demak dengan data harian tahun 2019-2024. Oleh karena itu penelitian ini bertujuan melakukan prediksi SWH di wilayah Semarang-Demak dengan membandingkan algoritma XGBoost dengan *Random Forest* (RF).

Kontribusinya yaitu mengetahui performa algoritma AI (XGBoost dan RF) untuk prediksi SWH yang paling akurat, sehingga dapat digunakan dalam acuan para peneliti berikutnya dalam memilih model AI yang tepat, dan berguna bagi stakeholder dalam melakukan mitigasi bencana hidrometeorologi di pesisir pantai Semarang-Demak.

II. METODE

Penelitian ini menggunakan pendekatan analisis eksploratif kuantitatif dengan menggunakan metode algoritma kecerdasan buatan (AI). Pemakaian model perbandingan algoritma *Machine Learning* (ML) menggunakan *Extreme Gradient Boosting* (XGBoost) dengan *Random Forest* (RF) untuk menemukan performa terbaik dalam memprediksi tinggi gelombang laut (SWH) di pantai utara Semarang-Demak. Sehingga lokasi penelitian ini adalah di wilayah pantai Semarang-Demak dengan obyek pengamatan dikantor Badan Meteorologi Klimatologi dan Geofisika (BMKG) yang lokasi kantor dan instrumen pengukurannya dilakukan di pelabuhan Tanjung Mas Semarang. Pemilihan kedua algoritma tersebut didasarkan atas studi literatur terkait dengan SLR, SWH, dan metode prediksi dengan model AI yang dibahas pada subbab pendahuluan. Tahapan Penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Studi Literatur dan Pengumpulan Data

Studi literatur dilakukan pada tahap pertama penelitian. Tujuannya untuk menentukan pemilihan model kecerdasan buatan (AI) yang sesuai untuk melakukan analisis prediksi terkait dengan kenaikan gelombang laut (SWH) dan kenaikan muka air laut (SLR). Penentuan algoritma XGBoost dan *Random Forest* setelah dilakukan review pada literatur pada riset-riset sebelumnya yang digunakan untuk prediksi. Hal ini mengingat kedua algoritma tersebut relatif efisien namun memiliki performa tingkat akurasi prediksi yang baik untuk penerapan dengan data time series yang relatif kecil hingga sedang terkait kapasitas data, serta jangka waktu yang pendek hingga sedang[18][21]. XGboost mampu meningkatkan meningkatkan prediksi SWH dengan menunjukkan error (MAE) yang sangat kecil[23], dan efisien dalam mengekstrak fitur penting dan mencapai RMSE yang tinggi akurasi[24]. XGBoost juga lebih akurat dibanding AdaBoost dalam teknik resempling dengan SMOTE[25]. Algoritma XGBoost dan RF sebagai metode ML terkemuka untuk prediksi perubahan muka laut, mengungguli pendekatan statistik tradisional[12]. Meskipun keduanya merupakan tipe ensemble, namun XGboost bekerja dengan cara boosting (serial), sedangkan RF dengan cara bagging (paralel)[26]. Studi literatur juga telah menunjukkan terjadinya SLR dan SWH di laut pantai utara Jawa Tengah sebagai acuan dan landasan untuk melakukan analisis perbandingan tingkat akurasi prediksi pada tahun berikutnya pada lokasi yang sama. Rumus XGBoost dan RF sebagai berikut.

$$\text{XGBoost untuk Prediksi : } \hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (1)$$

$$\text{Random Forest : } \hat{y} = \frac{1}{T} \sum_{t=1}^T f_t(x) \quad (2)$$

Selanjutnya dilakukan pengumpulan data yaitu berupa Variabel data yang digunakan untuk menentukan SLR dan SWH. Variabel datanya meliputi tinggi gelombang signifikan (H_s), periode gelombang ($T_s/t01$), arah datang gelombang (Dir), kecepatan angin (K_t) dan arah angin lokal (Dir), tekanan udara (Mb), serta arus yaitu berupa arah dan kecepatan (Cm/s). Data primer ini sangat bernilai karena menggambarkan kondisi aktual di lokasi penelitian. Pengamatan dan pengukuran variabel data tersebut dilakukan setiap jam pada instrumen Palm

dan sensor yang dipasang di sekitar laut Semarang- Demak. Data-data penelitian tersebut merupakan data histori yang dikumpulkan secara harian selama 6 tahun (2019-2024), dengan jumlah record (hari) sebanyak 2192 hari yang didapatkan dari BMKG Kemaritiman Kelas II Jawa Tengah. Data record tersebut disimpan dalam bentuk file excel (.xlsx), dan csv. Record data tersebut merupakan catatan rata-rata harian pada data yang tercatat setiap jam, sehingga dari 24 data SWH dibagi menjadi 24 jam.

B. Preprocessing dan Normalisasi Data

Pada tahap preprocessing data yang telah disimpan dalam format .xlsx atau .csv, selanjutnya disusun dengan menambahkan atribut-atribut yang menjadi fitur atau label pada setiap record data. Ini sangat penting untuk menteukan perlakuan data pada tahap analis prediksi. Sedangkan normalisasi berfungsi untuk melakukan pengecekan keadaan data normal atau tidak (missing data), data normal berisi data (tidak kosong) dan isi datanya adalah menunjukkan nilai yang wajar. Setelah dilakukan normalisasi dari jumlah 2192 record, ternyata terdapat 1 record data yang terjadi missing. Sehingga data yang dinyatakan valid untuk dilakukan proses analisis prediksi sebesar 2191.

Pembagian data pelatihan dan pengujian menggunakan metode chronological hold-out, yang mempertahankan urutan waktu asli dari data deret-waktu. Ini untuk menjaga validitas temporal dan menghindari kebocoran informasi (*data leakage*) dari masa depan ke masa lalu. Skema yang digunakan training set tahun 2019-2023 untuk melatih model RF dan XGBoost dalam mengenali pola historis. Sedangkan data tahun 2024 digunakan untuk menguji kemampuan generalisasi model terhadap data baru yang tidak pernah dilihat sebelumnya. Alasan Pemilihan Chronological Hold-Out adalah data time-series memiliki dependensi waktu, dapat digunakan untuk proyeksi kedepan, dan menghindari overfitting semu.


Gambaran data yang telah dilakukan cleansing data dengan struktur label atau fitur yang mempengaruhi SWH dapat dilihat seperti pada Gambar 2.

	Tanggal	Kec_rata-rata	Kec_Max	Arah	Kec_Arus	Arah_arus_laut	
0	01/01/2019	4.0	6	340	5	90	
1	02/01/2019	3.0	9	140	4	247	
2	03/01/2019	4.0	9	10	4	215	
3	04/01/2019	5.0	13	260	7	213	
4	05/01/2019	4.0	12	310	5	210	
...	...	...	...	...	...	...	
2187	27/12/2024	2.0	6	110	7	82	
2188	28/12/2024	3.0	8	200	11	78	
2189	29/12/2024	3.0	7	300	10	87	
2190	30/12/2024	2.0	12	340	13	93	
2191	31/12/2024	4.0	130	300	13	99	
	Tekanan	hs	t01	dir	Rata-rata	Max	Min
	1009.8	1.1	5.1	315.0	85.5	107	60
	1009.8	0.8	4.9	315.0	82.8	104	45
	1010.9	0.6	5.1	316.0	81.6	105	50
	1011.3	0.3	4.9	316.0	88.3	115	55
	1011.4	0.1	4.5	313.0	86.6	110	55
	...	...	...	...	...	...	...
	1009.8	0.3	3.8	322.0	149.5	176	125
	1009.2	0.4	3.7	316.0	147.5	168	122
	1009.2	0.4	3.9	324.0	147.3	178	112
	1008.7	0.8	4.1	323.0	154.9	182	138
	1008.4	0.9	4.9	319.0	146.0	168	130

[2191 rows x 13 columns]


Gambar 2. Struktur Data Variabel Tinggi Gelombang Laut (SWH) Pasca Cleansing Data

Berdasarkan struktur data variabel SHW seperti pada Gambar 2, maka selanjutnya dapat dibuat visualisasi data dengan model scater plot untuk menunjukkan hubungan antar dua variabel data yang terlibat dalam periode tertentu sesuai data time series tahun 2019 sampai tahun 2024. Gambar 3 menunjukkan hasil tinggi gelombang dan periode gelombang. Guna menganalisis data time series 2019-2024 maka perlu dihitung rata-rata nilai data dalam jangka waktu 30 harian yang disebut dengan Moving Avarage (MA) yang hasilnya dapat dilihat pada Gambar 3 dan Gambar 4. Scater plot MA tersebut menggambarkan pola dari data asli (aktual) SWH yang juga ditunjukkan dengan garis regresi linear untuk menunjukkan perkembangan data time series secara umum.




Gambar 3. Scatting Plot Variabel Tinggi Gelombang Signifikan (Hs) dan Periode Gelombang (Ts/t01)

Pada Gambar 3, pola gelombang laut selama tahun 2019-2025, warna biru merupakan data asli dari parameter gelombang laut, warna garis hitam merupakan rata-rata bulanan selama 30 hari dan garis merah putus-putus merupakan regresi linear untuk melihat kondisi tren arah arus selama kurun waktu 2019-2025. Pada gambar grafik kiri menunjukkan Hs terhadap waktu, sedangkan grafik kanan menunjukkan T01 terhadap waktu. Pada grafik Hs, terlihat adanya puncak musiman yang muncul secara berulang setiap tahun, kemungkinan besar berkaitan dengan periode musim angin atau monsun yang menguatkan tinggi gelombang laut. Lonjakan ini menunjukkan kejadian ekstrem gelombang tinggi, yang seringkali terjadi di wilayah tropis selama musim hujan atau akibat aktivitas siklon tropis. Meskipun terdapat variabilitas antar tahun, garis regresi linear menunjukkan sedikit tren peningkatan tinggi gelombang dari tahun ke tahun.



Gambar 4. Scatting Plot Arah Angin(Dir) dan Kecepatan Arus (Cm/s)



Gambar 5. Pola Kecepatan Angin Selama Tahun 2019-2025

Pada Gambar 5 warna kuning merupakan data asli dari parameter kecepatan angin, warna garis hitam merupakan rata-rata bulanan selama 30 hari dan garis merah putus-putus merupakan regresi linear untuk melihat kondisi tren arah arus selama kurun waktu 2019-2025. Terlihat bahwa Kec_rata-rata menunjukkan pola osilasi yang relatif konsisten hingga awal 2023, dengan nilai yang sebagian besar berkisar antara 3–5 m/s. Setelah tahun 2023, variabilitas meningkat dan nilai kecepatan angin rata-rata secara umum menunjukkan penurunan, sebagaimana tercermin pada arah negatif dari garis regresi linear. Fenomena ini dapat mengindikasikan adanya penurunan gradual dalam nilai pusat (*central tendency*) dari deret waktu tersebut, yang diidentifikasi secara statistik sebagai tren negatif jangka panjang. Penurunan ini juga disertai peningkatan sebaran data dan munculnya

lebih banyak nilai ekstrem rendah pasca 2023, yang mengimplikasikan peningkatan variabilitas intraperiode. Sementara itu, grafik sebelah kanan menunjukkan dinamika Kec_Max dengan representasi yang serupa. Nilai kecepatan angin maksimum cenderung menunjukkan kestabilan dalam kisaran 10–20 m/s selama hampir seluruh periode, yang ditunjukkan oleh rata-rata bergerak (MA 30 hari) yang relatif datar.

Penelitian ini menganalisis SWH waktu sangat penting karena banyak pola musiman yang berulang secara periodik setiap tahun atau bulan. Fitur waktu tidak direpresentasikan secara langsung sebagai bilangan bulat (misal: bulan = 1 hingga 12), karena representasi tersebut tidak mencerminkan hubungan periodik antar nilai waktu. Sebaliknya, digunakan pendekatan encoding waktu secara siklikal melalui fungsi sinus dan kosinus untuk bulan dan hari, dengan tujuan agar model dapat memahami hubungan periodik waktu secara lebih alami.

C. Analisis Variabel dan Pemodelan Machine Learning

Analisis data variabel berfungsi untuk menentukan pemilihan variabel yang digunakan untuk kebutuhan prediksi SLR dan SWH menggunakan pemodelan *Machine Learning* (ML) dengan algoritma XGBoost dan *Random Forest*. Langkah-langkah yang perlu dilakukan :

1. Membaca dan menyiapkan data variabel yang dibutuhkan melalui file excel atau csv yang sudah dilakukan normalisasi. Langkah ini selain menentukan jumlah data aktual yang didasarkan atas waktu (time series) juga melakukan konversi numerik untuk nilai variabel (Hs, t01, Dir, rata-rata, max, dan Min) dalam waktu hari, bulan, dan tahun. Fitur waktu tidak direpresentasikan secara langsung sebagai bilangan bulat karena representasi tersebut tidak mencerminkan hubungan periodik antar nilai waktu. Sebaliknya, digunakan pendekatan encoding waktu secara siklikal melalui fungsi sinus dan kosinus untuk bulan dan hari, dengan tujuan agar model dapat memahami hubungan periodik waktu secara lebih alami.
2. Menentukan formulasi pemodelan XGBoost dan *Random Forest* untuk prediksi SWH dan SLR.
3. Menghitung Performasi model Prediksi dengan *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan *R-squared* (R^2). Rumus evaluasi model untuk prediksi sebagai berikut.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (6)$$

D. Evaluasi Performa Model Prediksi dan Interpretasi Hasil

Evaluasi performa model prediksi SLR dan SWH menggunakan matrik evaluasi RMSE, MAE, MAPE, dan R^2 . Hasil metrik evaluasi tersebut yang didasarkan atas variabel data yang mempengaruhi SLR dan SWH selanjutnya dilakukan visualisasi berupa plot aktual vs prediksi, residual plot, dan feature importance. Tujuannya adalah untuk mengevaluasi performa model secara kuantitatif dan kualitatif, serta memahami perilaku model. Setelah dilakukan evaluasi model langkah terakhir adalah interpretasi hasil dan validasi, tujuannya untuk memastikan bahwa model tidak hanya akurat secara angka, tetapi juga relevan, andal, dan dapat dipercaya secara ilmiah dan praktis.

III. HASIL DAN PEMBAHASAN

A. Tren Kenaikan Muka Air Laut (SLR)


Berdasarkan data aktual yang dihitung dari data bersih sebanyak 2191 hari (selama 6 tahun), maka tren Kenaikan Muka Laut (SLR) dapat ditentukan perkembangannya pada setiap periode. Setiap tahun, permukaan laut di lokasi pengamatan naik rata-rata sebesar 9.352 cm. Ini tergolong cukup tinggi jika dibandingkan dengan rata-rata global IPCC (sekitar 3.5 mm/tahun), sehingga kemungkinan ini adalah SLR lokal / regional yang

dipengaruhi juga oleh pasang surut, iklim musiman, atau penurunan muka tanah (subsidence). Nilai R^2 (R-squared) : 0.930 (93%) adalah sangat tinggi, ini menunjukkan tren konsisten dan signifikan secara statistik. Model linear cocok untuk memprediksi SLR jangka pendek-menengah. Tren SLR dapat dilihat pada Gambar 6.



Gambar 6. Tren SLR Tahunan di Laut Utara Semarang-Demak Periode 2019-2024

Meskipun tren tahunan terlihat stabil, namun berdasarkan tren data harian, data harian menunjukkan banyak kejadian fluktuatif dan ekstrem lokal. Kenaikan cepat bisa terjadi akibat cuaca ekstrem (badai, hujan ekstrem), anomali pasang, dan tekanan atmosfer rendah. SLR tahunan digunakan sebagai indikator jangka panjang yang berguna untuk perencanaan pesisir. Sedangkan SLR bulanan dan harian sangat penting untuk peringatan dini banjir rob atau gelombang tinggi. Pada Gambar 6, garis ungu memperlihatkan perubahan harian SLR dalam skala cm, dirata-ratakan per 7 hari dengan fluktuasi lebih kecil (sekitar 1–3 cm) tetapi konsisten sepanjang tahun. Terdapat titik lonjakan tertinggi yaitu 6.343 cm/hari menjelang akhir 2024. Tren kenaikan harian terlihat pada Gambar 7.



Gambar 7. Tren SLR Harian di Laut Utara Semarang-Demak Periode 2019-2024


B. Tren Tinggi Gelombang Signifikan (SWH)

Pada tren tinggi gelombang signifikan (SWH) berdasarkan data aktual 2019-2024, maka rata-rata kenaikan perhari : 0.033, perbulan : 0.058, dan pertahun : 0.036. Ini menunjukkan bahwa selama 6 tahun terjadi kenaikan SWH rata-rata 3,6 cm/ tahun. Ini bisa disebabkan oleh: perubahan pola angin musiman, frekuensi badai atau gelombang tinggi meningkat, dan perubahan arus dan sirkulasi laut. Nilai R^2 adalah 0.793, yang berarti 79,3% variasi data SWH dapat dijelaskan oleh tren tahunan (regresi linier). Sedangkan sisanya 20,7% variasi dapat disebabkan oleh faktor lain seperti fluktuasi musiman, fenomena lokal, atau noise. Gambar 8 menunjukkan tren tahunan SWH di laut Semarang-Demak.



Gambar 8. Tren SWH Tahunan di Laut Utara Semarang-Demak Periode 2019-2024

Selanjutnya pada SWH harian, menampilkan selisih SWH antar hari (dihaluskan dengan *moving average* 7 hari). Pada Gambar 9 terlihat titik tertinggi: +0.286 m/hari, terjadi pada awal 2023, dan sebaran lonjakan harian terjadi hampir sepanjang tahun. Ini berarti kenaikan harian yang tajam bisa jadi indikator kejadian ekstrem seperti badai, angin kencang mendadak, atau arus deras. Sehingga perlu perhatian khusus untuk operasional pelayaran, tambak, dan aktivitas kelautan harian.



Gambar 9. Tren SWH Harian di Laut Utara Semarang-Demak Periode 2019-2024

C. Prediksi SWH dengan Random Forest dan XGBoost


Prediksi SWH di perairan laut Semarang-Demak dengan *Random Forest* (RF) dan XGBoost ini didasarkan pada hasil trend data aktual SWH tahun 2019-2024 sesuai bahasan pada subbab sebelumnya. Selanjutnya dilakukan perbandingan kinerja dua model ML, yakni RF dan XGBoost, untuk memprediksi tinggi gelombang signifikan (SWH). Hasil *Cross-Validation* menunjukkan bahwa kedua model memiliki akurasi sangat tinggi, dengan nilai rata-rata koefisien determinasi (R^2) sebesar 0.9877 untuk RF, dan 0.9987 untuk XGBoost. Evaluasi pada data uji memperkuat hasil tersebut, di mana XGBoost unggul secara signifikan dengan nilai RMSE: 0.0099, MAE: 0.0043, dan MAPE 1.6%, dibandingkan dengan RF yang mencatat RMSE: 0.0352, MAE: 0.0155, dan MAPE: 4.7%.

Analisis feature importance menunjukkan bahwa pada kedua model, fitur hs (tinggi gelombang signifikan historis) merupakan variabel paling dominan, dengan kontribusi sebesar 93.97% pada XGBoost dan 56.03% pada *Random Forest*. Fitur lain seperti Kec_Arus dan dir turut berkontribusi dalam model RF, sementara XGBoost hampir sepenuhnya bergantung pada hs . Secara keseluruhan, XGBoost terbukti lebih unggul dalam aspek akurasi dan presisi prediksi, menjadikannya pilihan utama untuk aplikasi yang membutuhkan estimasi tinggi gelombang yang sangat akurat. Di sisi lain, *Random Forest* tetap layak digunakan karena kemampuannya yang lebih fleksibel dalam menangani fitur yang lebih beragam dan kecenderungannya lebih tahan terhadap noise. Kedua model mengonfirmasi bahwa hs adalah prediktor kunci dalam estimasi SWH di wilayah studi. Tabel 1 menunjukkan hasil perbandingan prediksi SWH antara RF dengan XGBoost.

TABEL 1
PERBANDINGAN PREDIKSI SWH ANTARA RF DAN XGBOOST

Aspek	Random Forest	XGBoost	Kesimpulan
R ² (CV mean)	0.9877	0.9987	XGBoost unggul
RMSE (cm)	3.52	0.99	XGBoost jauh lebih presisi
MAE (cm)	1.55	0.43	XGBoost unggul
MAPE	4.7%	1.6%	XGBoost unggul
Feature Diversity	Lebih merata (6 fitur aktif)	Didominasi 1 fitur (hs)	RF lebih menyebar
Kompleksitas Model	Lebih sederhana	Lebih kompleks, lebih optimal	Tergantung kebutuhan

Berdasarkan Tabel 1 tersebut, model XGBoost menunjukkan performa yang lebih unggul dalam prediksi tinggi gelombang signifikan (SWH), dengan tingkat error yang sangat kecil dan akurasi yang hampir sempurna. Meskipun demikian, *Random Forest* tetap merupakan pilihan yang baik, terutama apabila dibutuhkan model yang lebih tahan terhadap noise dan lebih mudah diinterpretasikan. Untuk kebutuhan prediksi dengan presisi tinggi, XGBoost merupakan pilihan terbaik karena kemampuannya dalam menangkap pola dengan sangat akurat. Kedua model secara konsisten menegaskan bahwa fitur *hs* (tinggi gelombang signifikan historis) merupakan prediktor utama dalam estimasi SWH, sementara *Kec_Arus* (kecepatan arus laut) dan *dir* (arah gelombang) berperan sebagai fitur pelengkap yang turut berkontribusi penting.



Gambar 10. Perbandingan Data Aktual dengan Prediksi untuk SWH Periode 2019-2024


Berdasarkan grafik Gambar 10, dan dan hasil pada Tabel 1 yang ditampilkan merupakan hasil perbandingan kinerja dua model prediksi, yaitu *Random Forest* (RF) dan XGBoost, terhadap tinggi gelombang signifikan (SWH) selama periode 2019–2024. Grafik tersebut menggambarkan hubungan antara data aktual (dalam bentuk garis putus-putus berwarna) dengan hasil prediksi RF (garis hitam solid) dan XGBoost (garis abu putus-putus), yang diplot terhadap sumbu waktu (tahun) dan nilai SWH (dalam meter). Secara visual, kedua model menunjukkan hasil prediksi yang sangat mendekati pola data aktual. Model XGBoost tampil sangat presisi dan hampir identik dengan data observasi, termasuk dalam menangkap titik-titik ekstrem atau outlier. Sementara itu, *Random Forest* juga menunjukkan akurasi yang baik, namun cenderung sedikit melakukan overestimasi atau underestimasi pada kondisi gelombang tinggi. Hal ini menunjukkan bahwa meskipun kedua model efektif dalam mengikuti tren historis SWH, XGBoost memberikan prediksi yang lebih halus dan akurat, terutama pada fluktuasi ekstrem. Metrik perbandingannya dapat dilihat pada Tabel 2 berikut.

TABEL 2
METRIK PERBANDINGAN RF DENGAN XGBOOST UNTUK SWH

Metrik	Random Forest	XGBoost	Arti
RMSE	0.0352	0.0099	XGBoost lebih presisi (error lebih kecil)
MAE	0.0155	0.0043	Rata-rata error absolut jauh lebih kecil di XGBoost
MAPE (%)	4.7%	1.6%	Tingkat kesalahan relatif XGBoost sangat kecil
R ² Score	0.9858	0.9989	Akurasi XGBoost mendekati sempurna
Mean CV R ²	0.9877	0.9987	Konsistensi model XGBoost sangat tinggi

Pada hasil evaluasi tersebut dapat disimpulkan bahwa model XGBoost secara konsisten menunjukkan performa yang lebih unggul dibandingkan *Random Forest* dalam prediksi tinggi gelombang signifikan (SWH). XGBoost tidak hanya memiliki akurasi prediksi yang lebih tinggi, tetapi juga mampu menangkap lonjakan gelombang ekstrem dengan sangat baik, menjadikannya unggul dalam hal presisi. Dari segi kestabilan, kedua model cukup andal, namun hasil cross-validation menunjukkan bahwa XGBoost lebih konsisten. Secara visual, prediksi XGBoost sangat mendekati nilai aktual, menggambarkan kemampuan model dalam mengikuti pola data

secara akurat. Oleh karena itu, XGBoost direkomendasikan sebagai pilihan utama, khususnya untuk aplikasi yang membutuhkan tingkat presisi tinggi dan detail, seperti sistem peringatan dini bencana pesisir atau kajian klimatologis jangka panjang. Berdasarkan hasil prediksi SWH menggunakan RF dan XGBoost sesuai dengan data aktual pada tahun 2019–2024, berikutnya dapat diprediksi untuk tahun 2025. Grafik prediksi dapat dilihat seperti pada Gambar 10.



Gambar 11. Grafik Prediksi SWH antara RF dengan XGBoost Selama Tahun 2025


Berdasarkan grafik prediksi SWH tahun 2025 seperti Gambar 11, terlihat bahwa baik model RF maupun XGBoost memproyeksikan pola musiman yang serupa, dengan puncak gelombang tinggi terjadi pada bulan Januari hingga Februari, kemudian mengalami penurunan tajam mulai Maret hingga April, dan mencapai kondisi relatif tenang sepanjang Mei hingga Oktober. Menjelang akhir tahun, yaitu pada November dan Desember, kedua model kembali memprediksi peningkatan gelombang yang menandai musim gelombang tinggi akhir tahun. Meskipun pola umum keduanya serupa, prediksi dari model XGBoost cenderung lebih halus namun ekstrem, dengan perubahan nilai yang lebih tajam baik saat menurun maupun saat meningkat, dibandingkan dengan *Random Forest*. Hal ini menunjukkan bahwa XGBoost memiliki sensitivitas yang lebih tinggi dalam menangkap fluktuasi harian gelombang, sehingga lebih efektif untuk mengidentifikasi perubahan mendadak pada kondisi laut.

Hasil penelitian menunjukkan bahwa baik model *Random Forest* (RF) maupun XGBoost (XGB) memiliki performa yang sangat baik dalam memprediksi tinggi gelombang signifikan (Significant Wave Height/SWH) untuk tahun 2025, dengan XGBoost secara konsisten menunjukkan keunggulan dari segi akurasi dan presisi. Nilai rata-rata R^2 dari hasil validasi silang mencapai 0.9877 untuk RF dan 0.9987 untuk XGB, sementara evaluasi pada data uji menunjukkan R^2 sebesar 0.9858 untuk RF dan 0.9989 untuk XGB. Selain itu, nilai galat yang dihasilkan oleh XGBoost jauh lebih kecil, dengan RMSE sebesar 0.0099, MAE 0.0043, dan MAPE hanya 1.6%, dibandingkan dengan RF yang memiliki RMSE 0.0352, MAE 0.0155, dan MAPE 4.7%. Analisis feature importance dari kedua model menegaskan bahwa variabel *hs* (tinggi gelombang signifikan historis) merupakan prediktor utama, dengan bobot dominan 93.97% pada XGBoost dan 56.03% pada *Random Forest*, sedangkan fitur lain seperti *Kec_Arus* dan *dir* memiliki pengaruh yang lebih kecil. Berdasarkan prediksi harian yang telah dihasilkan dan disimpan dalam file `prediksi_swh_2025.csv`, kedua model mampu mengikuti pola musiman SWH, namun XGBoost lebih sensitif dalam menangkap variasi ekstrem. Sehingga, XGBoost direkomendasikan sebagai model yang lebih optimal untuk proyeksi SWH tahun 2025, terutama untuk keperluan analisis presisi tinggi seperti sistem peringatan dini atau perencanaan adaptasi wilayah pesisir khususnya di wilayah perairan laut Semarang-Demak.

D. Prediksi SLR dengan Random Forest dan XGBoost

Pada prediksi SLR di laut Semarang-Demak hasilnya menunjukkan bahwa RF memiliki performa yang lebih baik dibandingkan XGBoost dalam hal akurasi dan efisiensi prediksi pada data uji. Nilai koefisien determinasi (R^2) untuk RF sebesar 0.9402 mengindikasikan bahwa model mampu menjelaskan 94,02% variasi data aktual, sementara XGBoost hanya mencapai R^2 sebesar 0.8827. Selain itu, nilai galat prediksi RF juga lebih rendah, dengan MAE sebesar 1.097 cm, RMSE 2.456 cm, dan MAPE 0.73%, dibandingkan XGBoost yang mencatat MAE 1.782 cm, RMSE 3.438 cm, dan MAPE 1.21%. Perbedaan ini menunjukkan bahwa RF lebih presisi dalam memprediksi nilai SLR secara absolut maupun relatif, serta lebih stabil dalam menangani distribusi data yang bervariasi. Oleh karena itu, dalam konteks prediksi SLR periode 2019–2024, model *Random Forest*

dapat dianggap lebih unggul dan layak digunakan untuk aplikasi yang membutuhkan ketelitian tinggi dalam estimasi muka laut. Grafik pada Gambar 12 menunjukkan hasil prediksi SLR tahun 2019-2024.




Gambar 12. Grafik Prediksi SLR Tahun 2019-2025

Dalam grafik pada Gambar 12 tersebut, garis biru menggambarkan data SLR aktual, sementara garis putus merah dan oranye masing-masing mewakili hasil prediksi dari RF dan XGBoost, yang telah diperlunak menggunakan rata-rata bergerak 7 hari. Hasil visualisasi menunjukkan bahwa kedua model mampu mengikuti tren SLR secara umum dengan baik, di mana model RF cenderung lebih mendekati data aktual terutama pada periode fluktuasi tajam. Hal ini menunjukkan bahwa baik *Random Forest* maupun XGBoost memiliki kapabilitas prediktif yang andal terhadap dinamika muka laut, dengan keunggulan relatif RF dalam menyesuaikan respons terhadap perubahan ekstrem jangka pendek.

Selanjutnya untuk prediksi SLR sepanjang tahun 2025, hasil penelitian menunjukkan bahwa kedua model, RF dan XGBoost, mampu memprediksi SLR dengan tingkat akurasi yang sangat tinggi. Model *Random Forest* mencatat nilai rata-rata R^2 dari validasi silang sebesar 0.9889 dan nilai R^2 pada data uji sebesar 0.9892, dengan RMSE 1.8973 cm, MAE 1.4302 cm, dan MAPE 1.3%, yang mengindikasikan bahwa model ini stabil dan presisi dalam menjelaskan hampir 99% variasi data SLR. Hasil ini menunjukkan bahwa *Random Forest* sangat andal dalam menangani data historis dan mampu memberikan prediksi yang konsisten untuk periode 2025.

Sementara itu, model XGBoost menunjukkan performa yang sedikit lebih unggul, dengan nilai rata-rata R^2 dari validasi silang sebesar 0.9915 dan R^2 pada data uji sebesar 0.9921. Nilai error yang lebih kecil (RMSE 1.6220 cm, MAE 1.2877 cm, dan MAPE 1.1%) menandakan bahwa XGBoost mampu memberikan prediksi SLR yang lebih presisi. Dengan hasil tersebut, XGBoost direkomendasikan sebagai model yang lebih optimal untuk proyeksi SLR jangka pendek hingga menengah, terutama pada aplikasi yang memerlukan ketelitian tinggi seperti perencanaan adaptasi wilayah pesisir, sistem peringatan dini, dan studi klimatologis. Kedua model telah berhasil menghasilkan prediksi bulanan sepanjang tahun 2025 dan dapat digunakan untuk analisis lanjutan berbasis data. Hasilnya dapat dilihat seperti pada Gambar 13.



Gambar 13. Hasil Perbandingan Prediksi SLR dengan RF dan XGBoost untuk Tahun 2025

E. Diskusi dan Rekomendasi

Model XGBoost sangat presisi untuk pPrediksi SWH, hal ini karena didominasi oleh satu variabel utama, yaitu tinggi gelombang historis (h_s), yang memiliki kontribusi lebih dari 90% dalam *feature importance*. Selain itu dengan kemampuannya mengoptimalkan loss function secara bertahap, XGBoost dapat menyesuaikan model

dengan sangat akurat terhadap data musiman dan ekstrem seperti puncak gelombang. XGBoost juga mampu menangani non-linearitas dan interaksi antar fitur dengan sangat baik, sehingga model dapat memetakan dinamika laut yang kompleks namun terprediksi secara fisik. Sementara *Random Forest* Lebih Stabil untuk Prediksi SLR karena dipengaruhi oleh banyak variabel seperti gelombang pasang, subsidence, arus, tekanan udara, anomali atmosfer, dan lainnya.

Berdasarkan hasil evaluasi dan analisis prediksi, disarankan untuk menggunakan XGBoost dalam aplikasi yang memerlukan prediksi tinggi gelombang laut (SWH) dengan presisi tinggi, seperti peringatan dini gelombang ekstrem, operasional pelayaran, serta manajemen risiko maritim. Sementara itu, *Random Forest* direkomendasikan sebagai model utama untuk prediksi jangka pendek-menengah kenaikan muka laut (SLR), karena lebih stabil terhadap data yang mengandung noise dan lebih adaptif terhadap variasi lokal. Hasil prediksi model ini dapat dimanfaatkan oleh instansi pemerintah, seperti BMKG dan BPBD, untuk mendukung kebijakan mitigasi bencana hidrometeorologi, perencanaan zonasi pesisir, serta peningkatan ketahanan infrastruktur pesisir. Studi ini juga memberikan dasar kuat bagi pengembangan sistem prediksi berbasis AI untuk pemantauan dinamika laut secara berkala di wilayah pesisir utara Jawa Tengah.

IV. SIMPULAN

Penelitian ini berhasil mengevaluasi dan membandingkan performa algoritma *Random Forest* (RF) dan XGBoost dalam memprediksi kenaikan muka laut (Sea Level Rise/SLR) dan tinggi gelombang signifikan (Significant Wave Height/SWH) di wilayah perairan Semarang–Demak selama periode 2019–2025. Hasil prediksi menunjukkan bahwa untuk variabel SWH, model XGBoost secara konsisten memberikan performa yang lebih akurat dibandingkan *Random Forest*, dengan nilai koefisien determinasi (R^2) mencapai 0.9989 dan nilai galat sangat rendah (RMSE = 0.0099 m; MAE = 0.0043 m; MAPE = 1.6%). XGBoost juga lebih sensitif dalam menangkap lonjakan ekstrem dan pola musiman gelombang laut. Sebaliknya, dalam memprediksi SLR, model *Random Forest* menunjukkan kinerja yang lebih unggul dibanding XGBoost, terutama dalam hal kestabilan prediksi pada data uji dan kemampuan adaptasi terhadap fluktuasi harian, dengan nilai R^2 sebesar 0.9892 dan MAPE hanya 1.3%. Kedua model menegaskan bahwa variabel h_s merupakan fitur paling dominan dalam prediksi SWH, sedangkan SLR dipengaruhi oleh kombinasi faktor meteorologis dan oseanografis. Hasil riset ini menunjukkan bahwa penggunaan model ensemble dengan XGBoost dan RF dapat membentuk model yang lebih kuat dan akurat dengan tujuan untuk mengurangi error dan meningkatkan stabilitas akurasi pada operasi SWH dan SLR.

UCAPAN TERIMAKASIH

Terimakasih Kepada Pimpinan Badan Meteorologi Klimatologi dan Geofisika (BMKG) Kemaritiman Kelas II Jawa Tengah yang telah mendukung dalam pemberian data dan konsultasinya.

DAFTAR PUSTAKA

- [1] A. Supriyanto, E. Zuliarso, E. T. Suharmanto, H. Amalina, and F. Damaryanti, "Drought Prediction Using Lstm Model With Standardized Precipitation Index on the North Coast of Central Java," *Jurnal Teknik Informatika (Jutif)*, vol. 5, no. 6, pp. 1873–1882, 2024, doi: 10.52436/1.jutif.2024.5.6.4159.
- [2] H. L. Gaol, M. Helmi, and A. Satriadi, "Analisis Perubahan Garis Pantai Wilayah Pesisir Menggunakan Metode DSAS (Digital Shoreline Analysis System) Di Pantai Tirang, Tugurejo Kota Semarang," *Indonesian Journal of Oceanography*, vol. 7, no. 1, pp. 21–31, 2025, doi: 10.14710/ijoce.v7i1.25459.
- [3] I. A. Abdullah, Danardono, and H. Z. Hadibasyir, *The Dynamics of Changes in the Coastline of the Sayung Coastal Community in Demak Regency Using Remote Sensing Imagery*. Atlantis Press SARL, 2023. doi: 10.2991/978-2-38476-066-4_28.
- [4] W. Han *et al.*, "Sea level extremes and compounding marine heatwaves in coastal Indonesia," *Nature Communications*, vol. 13, no. 1, pp. 1–12, 2022, doi: 10.1038/s41467-022-34003-3.
- [5] R. S. Ponto *et al.*, "Deep learning approaches to predict sea surface height above geoid in Pekalongan," *International Journal of Data and Network Science*, vol. 8, no. 2, pp. 743–752, 2024, doi: 10.5267/j.ijdns.2024.1.004.
- [6] W. Setianingsih, B. Sasmito, and N. Bashit, "Analisis Level Rise di Laut Utara Jawa Terhadap Perubahan Garis Pantai Wilayah Demak Pada tahun 2006-2016," *Jurnal Geodesi Undip*, vol. 7, no. April, pp. 53–64, 2018.
- [7] C. Tay *et al.*, "Sea-level rise from land subsidence in major coastal cities," *Nature Sustainability*, vol. 5, no. 12, pp. 1049–1057, 2022, doi: 10.1038/s41893-022-00947-z.
- [8] G. Mulyasari, Irfham, L. R. Waluyati, and A. Suryantini, "Understanding and adaptation to climate change of fishermen in the northern coastal of Central Java, Indonesia," *IOP Conference Series: Earth and Environmental Science*, vol. 724, no. 1, 2021, doi: 10.1088/1755-1315/724/1/012094.
- [9] S. Susilo *et al.*, "GNSS land subsidence observations along the northern coastline of Java, Indonesia," *Scientific Data*, vol. 10, no. 1, pp. 1–8, 2023, doi: 10.1038/s41597-023-02274-0.
- [10] K. Triana and A. J. Wahyudi, "Sea level rise in Indonesia: The drivers and the combined impacts from land subsidence," *ASEAN Journal on Science and Technology for Development*, vol. 37, no. 3, pp. 115–121, 2020, doi: 10.29037/AJSTD.627.
- [11] R. Murtiaji, M. Irfani, I. Fauzi, A. S. D. Marta, C. I. Sukmana, and D. A. Wulandari, "Methods for addressing tidal floods in coastal cities: An overview," *IOP Conference Series: Earth and Environmental Science*, vol. 1224, no. 1, 2023, doi: 10.1088/1755-

- 1315/1224/1/012019.
- [12] A. S. Ayinde, Y. Huaming, and W. Kejian, "Review of *Machine Learning* methods for sea level change modeling and prediction," *Science of the Total Environment*, vol. 954, no. July, p. 176410, 2024, doi: 10.1016/j.scitotenv.2024.176410.
- [13] D. Khojasteh *et al.*, "The evolving landscape of sea-level rise science from 1990 to 2021," *Communications Earth and Environment*, vol. 4, no. 1, 2023, doi: 10.1038/s43247-023-00920-4.
- [14] R. A. Dhiya'ulhaq, A. Safira, I. Fahmiyah, and M. Ghani, "Ocean wave prediction using Long Short-Term Memory (LSTM) and *Extreme Gradient Boosting* (XGBoost) in Tuban Regency for fisherman safety," *MethodsX*, vol. 13, no. July, p. 103031, 2024, doi: 10.1016/j.mex.2024.103031.
- [15] A. Musbikhin, E. Sedyono, and C. E. Widodo, "Model Sea Levels Prediction With ARIMA for Coastal Area in Semarang," *Proceedings of the International Conference on Innovation in Science and Technology*, vol. 208, no. ICIST 2020, pp. 1–5, 2020.
- [16] D. Tarwidi, S. R. Pudjaprasetya, D. Adytia, and M. Apri, "An optimized XGBoost-based *Machine Learning* method for predicting wave run-up on a sloping beach," *MethodsX*, vol. 10, no. December 2022, p. 102119, 2023, doi: 10.1016/j.mex.2023.102119.
- [17] A. Durap, "Data-driven models for significant wave height forecasting: Comparative analysis of *Machine Learning* techniques," *Results in Engineering*, vol. 24, no. December, p. 103573, 2024, doi: 10.1016/j.rineng.2024.103573.
- [18] A. Callens, D. Morichon, S. Abadie, M. Delpey, and B. Liquey, "Using *Random Forest* and Gradient boosting trees to improve wave forecast at a specific location," *Applied Ocean Research*, vol. 104, no. July, 2020, doi: 10.1016/j.apor.2020.102339.
- [19] M. Azad and M. A. Uddin, "Prediction of Offshore Wave at East Coast of Malaysia—A Comparative Study," *Electronics (Switzerland)*, vol. 11, no. 16, pp. 1–17, 2022, doi: 10.3390/electronics11162527.
- [20] F. Anggraeni, D. Adytia, and A. W. Ramadhan, "Forecasting of Wave Height Time Series Using AdaBoost and XGBoost, Case Study in Pangandaran, Indonesia," *2021 International Conference on Data Science and Its Applications, ICoDSA 2021*, pp. 97–101, 2021, doi: 10.1109/ICoDSA53588.2021.9617524.
- [21] T. Kim and W. D. Lee, "Prediction of wave runup on beaches using interpretable *Machine Learning*," *Ocean Engineering*, vol. 297, no. May 2023, p. 116918, 2024, doi: 10.1016/j.oceaneng.2024.116918.
- [22] S. Leng, M. Hao, W. Shao, A. Marino, and X. Jiang, "A Technique for SAR Significant Wave Height Retrieval Using Azimuthal Cut-Off Wavelength Based on *Machine Learning*," *Remote Sensing*, vol. 16, no. 9, pp. 1–17, 2024, doi: 10.3390/rs16091644.
- [23] H. Hu and P. Chu, "Predicting Lake Erie Wave Heights using XGBoost," no. 2015, pp. 1–9, 2019, [Online]. Available: <http://arxiv.org/abs/1912.01786>
- [24] T. Song, Q. Yan, C. Fan, J. Meng, Y. Wu, and J. Zhang, "Significant Wave Height Retrieval Using XGBoost from Polarimetric Gaofen-3 SAR and Feature Importance Analysis," *Remote Sensing*, vol. 15, no. 1, 2023, doi: 10.3390/rs15010149.
- [25] C. E. Sukmawati, A. R. Pratama, H. Hikmayanti, and A. R. Juwita, "Jurnal Informatika : Jurnal pengembangan IT Optimasi AdaBoost dan XGBoost untuk Klasifikasi Obesitas Menggunakan SMOTE," vol. 10, no. 3, pp. 771–780, 2025, doi: 10.30591/jpit.v10i3.8536.
- [26] S. Fatima, A. Hussain, S. Bin Amir, S. H. Ahmed, and S. M. H. Aslam, "XGBoost and *Random Forest* Algorithms: An in Depth Analysis," *Pakistan Journal of Scientific Research*, vol. 3, no. 1, pp. 26–31, 2023, doi: 10.57041/pjosr.v3i1.946.