

PREDIKSI TINGGI GELOMBANG LAUT JAKARTA UTARA MENGGUNAKAN MACHINE LEARNING: PERBANDINGAN ALGORITMA ARIMA & SARIMA

Acep Saepul Zamil¹, Luthfi Anzani², Willdan Aprizal Arifin³

¹Sistem Informasi Kelautan, Universitas Pendidikan Indonesia, e-mail: acepsaepulzamil@upi.edu

²Sistem Informasi Kelautan, Universitas Pendidikan Indonesia, e-mail: luthfi_anzani@upi.edu

³Sistem Informasi Kelautan, Universitas Pendidikan Indonesia, e-mail: willdanarifin@upi.edu

ARTICLE INFO

Article history:

Received : 13 – Juni - 2023

Received in revised form : 14 – Juli - 2023

Accepted : 14 – Agustus - 2023

Available online : 1 – September - 2023

ABSTRACT

In predicting ocean waves in the next few days requires high accuracy. Therefore, the development of Machine Learning can be used to predict the condition of ocean waves. The representation of the accuracy of Machine Learning regarding wave height can determine the ship's decision to make a shipping route or allow fishermen to sail or not. This research was conducted in the Sunda Strait. In determining the calculation of the prediction of ocean waves using the ARIMA and SARIMA algorithms. The results of the predictions of the two Machine Learning algorithms are compared which will then take the best accuracy results. The data that will be used is taken from several years back (2015-2020) to train the model to get better results. The two prediction results from the accuracy are also compared with predictions from the BMKG station. The prediction results on September 20 - September 21 2022 show the wind direction from northeast to southeast with wind speeds of 1 - 6 knots with an average wave height range of 0.1 - 0.5 m.

Keywords: ARIMA, ocean wave, machine learning, prediction, SARIMA.

1. PENDAHULUAN

Laut Jakarta Utara merupakan perairan yang berada di sebelah utara Pulau Jawa yang digunakan sebagai salah satu pusat kegiatan ekonomi bagi penduduk. Hal tersebut didasari karena laut Jakarta Utara memiliki sumber daya yang beragam (Risandi *et al.*, 2021). Jenis kegiatan yang sering dilakukan salah satunya ialah sebagai rute penting bagi transportasi serta perdagangan untuk meningkatkan ekonomi. Rute dari transportasi sangat ditentukan oleh tinggi gelombang. Karena jika wilayah perairan memiliki gelombang yang sangat tinggi maka dapat membahayakan kapal transportasi (Khasanah, 2019). Oleh karena itu, perlu adanya peramalan atau prediksi tinggi gelombang yang akurat. Dalam penelitian ini, metode ARIMA dan SARIMA digunakan untuk pemodelan *time series*.

Gelombang laut tercipta karena adanya gesekan antara angin yang kuat dengan permukaan air laut (Kuswartomo *et al.*, 2021). Gelombang laut mempengaruhi kondisi berbagai aktivitas yang dilakukan dilaut. Ada alasan mendasar mengapa pengetahuan tentang kondisi gelombang laut untuk beberapa hari kedepan itu penting. Misalnya rute pelayaran dapat dioptimalkan dengan menghindari laut yang bergelombang

tinggi maupun memungkinkan para nelayan untuk berlayar atau tidak (James *et al*, 2018). Hal tersebut akan mengurangi dampak terhadap keterlambatan dalam pelayaran dan juga memberikan dampak baik terhadap nelayan. Karena gelombang laut yang tinggi akan membuat nelayan kesulitan dalam berlayar untuk mencari ikan dan aktivitas lainnya.

Prediksi mengenai tinggi gelombang laut tersebut tentu saja memerlukan keakuratan yang tinggi. *Machine Learning* menjadi salah satu perkembangan teknologi yang cukup maju dalam membuat prediksi di bidang kelautan. Salah satunya prediksi mengenai tinggi gelombang laut yang bersifat *time series*. Dalam penelitian ini algoritma *Machine Learning* yang digunakan untuk *time series* yaitu model *Autoregressive Integrated Moving Average* (ARIMA) dan *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Kedua model tersebut dibandingkan untuk menentukan hasil akurasi mana yang lebih baik.

Algoritma ARIMA dan SARIMA merupakan salah satu model yang sering digunakan dalam penelitian *time series*. Pada penelitian Putri & Sofro, (2022) digunakan untuk peramalan dalam menentukan jumlah keberangkatan penumpang pelayaran. Penelitian tersebut juga membandingkan algoritma ARIMA dan SARIMA dalam melakukan prediksi. Disebutkan hasil dari penelitian tersebut menunjukkan bahwa model ARIMA memiliki nilai *Mean Absolute Percentage Error* (MAPE) sebesar 16.15% sedangkan SARIMA dengan nilai MAPE 25.51%. ARIMA memiliki nilai MAPE terkecil, sehingga dapat dikatakan ARIMA merupakan model akurasi terbaik daripada SARIMA.

Penelitian ini bertujuan untuk melakukan perbandingan algoritma *time series Machine Learning* antara model ARIMA dan SARIMA dalam kasus tinggi gelombang di Jakarta Utara. Kedua model tersebut memiliki keunggulan masing-masing. ARIMA pada umumnya memiliki pola yang konstan dalam jangka waktu yang cukup panjang (Rashed *et al*, 2017). Penggunaan model ARIMA ini sudah terbukti memiliki kegunaan yang sangat baik dalam metode *time series* karena menggunakan metodologi yang dasar dalam memodelkan data bergantung pada baris data masa lalu. Sehingga memungkinkan untuk mendapatkan hasil pengujian yang lebih baik (Unnikrishnan *et al*, 2016). Sedangkan penggunaan model SARIMA memiliki pola fluktuasi secara musiman atau periodik secara berulang yang memiliki intensitas setiap satu tahun (Sutrisno *et al*, 2021). Sehingga hal tersebut menunjukkan bahwa model SARIMA memiliki karakteristik yang bersifat korelasi kuat dalam menentukan nilai pada pola yang bersifat musiman atau periode. Perbandingan akan dilakukan untuk mengetahui prediksi masa depan yang diperoleh dan menentukan model mana yang memiliki keakuratan lebih baik. Dimana hasil prediksi dari kedua model tersebut akan dilakukan pengujian berdasarkan data aktual tinggi gelombang. Model ARIMA dan SARIMA mempunyai pola perbedaan data yang berfluktuasi. Model ARIMA memiliki pola fluktuasi tidak tetap sedangkan model SARIMA memiliki pola musiman (Putri & Sofro, 2022).

2. TINJAUAN PUSTAKA

2.1. *Machine Learning*

Machine learning adalah suatu algoritma pembelajaran yang dapat menyajikan data-data dalam memprediksi serta menangani data yang amat besar (Danukusumo, 2017). *Machine learning* merupakan jenis kecerdasan buatan (AI) yang memungkinkan aplikasi perangkat lunak menjadi lebih akurat dalam memprediksi hasil tanpa diprogram secara eksplisit untuk melakukannya. Algoritma pembelajaran mesin menggunakan data historis sebagai input untuk memprediksi nilai output baru (Nurhidayat *et al*, 2021). *Machine learning* bergantung pada algoritma yang berbeda untuk memecahkan masalah data. Jenis algoritma yang digunakan tergantung pada jenis masalah yang ingin dipecahkan (Mahes, 2018). Dalam penelitian ini jenis *machine learning* menggunakan model ARIMA dan SARIMA karena kedua model tersebut berhubungan dengan prediksi atau peramalan yang bersifat *time series*.

2.2. Gelombang Laut

Gelombang laut merupakan salah satu fenomena alam yang begitu penting dalam dunia maritim. Karena informasi mengenai gelombang laut sangat dibutuhkan dalam berbagai hal yang berkaitan dengan transportasi laut, rute pelayaran, perikanan, pelabuhan, pengembangan pesisir serta mitigasi pantai (Siregar *et al*, 2020). Gelombang diciptakan oleh energi yang melewati air, bergerak di atas permukaan laut yang menyebabkan peningkatan ketinggian gelombang, semakin lama embusan angin maka kecepatan dan panjang gelombang akan terus meningkat (Ondara & Semeidi, 2017).

2.3. ARIMA

Metode ARIMA (*Autoregressive Integrated Moving Average*) ialah metode prediksi yang bersifat *time series* dengan mengamati variabel data masa lalu serta fenomena pola musiman yang biasanya

memiliki periode terukur yang sama (Berlinditya & Noeryanti, 2019). Pada umumnya, ARIMA hanya digunakan untuk peramalan jangka pendek saja, karena ARIMA ini memiliki pola yang datar sehingga tidak cocok untuk peramalan jangka panjang (Hadiansyah, 2017). Algoritma atau metode pembandingan dalam kasus yang sama yaitu prediksi ketinggian gelombang menggunakan algoritma *backpropagation*. Pada penelitian Raharja & Astra, (2018) ini menunjukkan metode *backpropagation* ANN menggunakan 12 *input layer*, 10 *hidden layer* serta 1 *output*. Dengan jumlah maksimal epoch sebesar 10.000, *learning rate* 0.1, error 0.01 dan momentum 0.95. Kemudian total data latih sejumlah 48 menghasilkan korelasi sebesar 0,99101 dan nilai MSE sebesar 0,00099745. Pada tahap pengujian diperoleh korelasi dengan nilai 0,9652 dan menghasilkan MSE sebesar 0,0042314.

ARIMA memiliki 3 klasifikasi model yaitu model AR (*autoregressive*), model MA (*moving average*) serta model ARMA (*autoregressive moving average*) atau model campuran yang memiliki fitur dari model AR dan MA.

2.3.1. AR (*autoregressive*)

AR dinyatakan dengan ordo p atau digambarkan dengan ARIMA ($p, 0, 0$). Berikut rumus dari AR:

$$X_t = \mu' + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t$$

dimana: μ' = suatu konstanta

ϕ_p = parameter autoregresif ke- p

e_t = nilai kesalahan pada saat t

2.3.2. MA (*moving average*)

MA dinyatakan dengan ordo q atau digambarkan dengan ARIMA ($0, 0, q$). Berikut rumus dari MA:

$$X_t = \mu' + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-k}$$

dimana: μ' = suatu konstanta

θ_1 sampai θ_q adalah parameter-parameter *moving average*

e_{t-k} = nilai kesalahan pada saat $t - k$

2.3.3. ARMA (*autoregressive moving average*)

Ada 2 model ARMA, yaitu ARMA murni dan ARMA yang telah dilakukan proses *differencing*. AR (1) murni dan MA (1) murni, dinyatakan ARIMA (1, 0, 1). Berikut rumus dari ARMA:

$$(1 - \phi_1 B)X_t = \mu' + (1 - \theta_1 B)e_t$$

AR(1)

MA(1)

Untuk ARMA yang mengalami proses *differencing* memiliki model ARIMA (p, d, q), dinyatakan dengan ARIMA (1, 1, 1). Berikut rumusnya:

$$(1 - B)(1 - \phi_1 B)X_t = \mu' + (1 - \theta_1 B)e_t$$

2.4. SARIMA

Metode SARIMA (*Seasonal Autoregressive Integrated Moving Average*) ialah metode *time series* perkembangan dari ARIMA yang dapat menunjukkan fluktuasi data secara periode dan secara berulang pada setiap tahun (Sutrisno *et al.*, 2021). Metode SARIMA ini tidak hanya digunakan dalam prediksi tinggi gelombang saja. Pada kasus yang berbeda dalam penelitian Kafara *et al.*, (2017) menganalisis data prediksi untuk memperkirakan curah hujan dengan menggunakan algoritma SARIMA. Dijelaskan bahwa metode SARIMA ini menunjukkan model SARIMA terbaik dengan nilai MAPE = 76,68 dan RMSE = 242,14. Jika dibandingkan dengan data aktualnya, metode SARIMA ini tidak sesuai. Baik prediksi data gelombang maupun data curah hujan, metode ini memiliki kesamaan karena berkaitan dengan peramalan.

SARIMA merupakan pola yang memiliki musiman. Dapat dinyatakan dengan notasi SARIMA (p, d, q) (P, D, Q). Dimana pola (p, d, q) merupakan pola bukan musiman pada model sedangkan (P, D, Q) merupakan bagian pola musiman. S sendiri merupakan bagian jumlah periode pada musiman. Berikut rumus SARIMA:

$$X_t(1 - B)^d(1 - B^S)^S = (1 - B\Phi_1)(1 - \theta_1 B^S)e_t$$

Dimana: $(1 - B) d$ = pembeda non-musiman

$(1 - B^S)$ = pembeda musiman

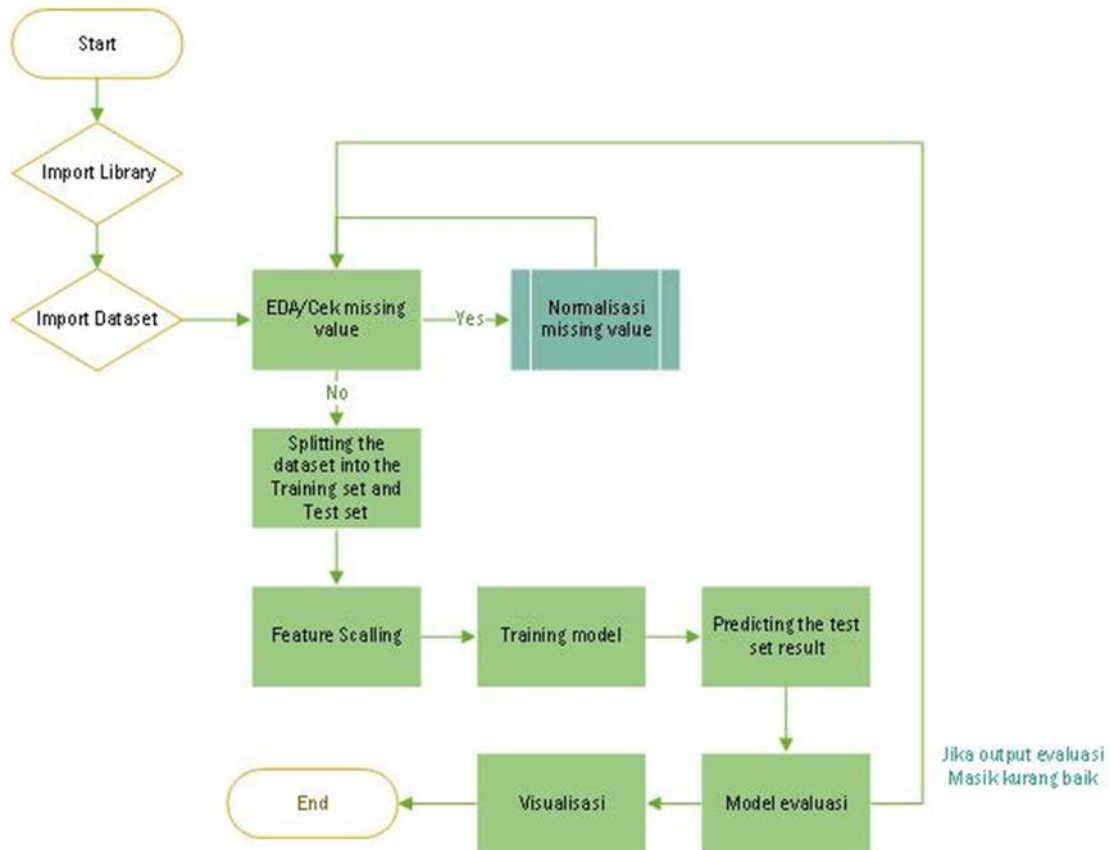
$\theta_1(B)$ = MA non seasonal

(B^S) = MA seasonal

Et = residual term.

3. METODOLOGI PENELITIAN

Penelitian ini menggunakan desain penelitian yang menggunakan pendekatan *machine learning* dengan tahapan code program secara runut dimulai dari *import library* dan dataset, cek *missing value*, *splitting data train set* dan *test set*, *Modelling*, *training model*, *predicting*, model evaluasi dan visualisasi



Gambar 1. Desain Penelitian

Pendekatan penelitian menggunakan model kuantitatif yaitu proses mengumpulkan dan menganalisis data numerik. Penelitian ini dapat digunakan untuk menemukan pola dan rata-rata, membuat prediksi, menguji hubungan sebab akibat, dan menggeneralisasi hasil ke populasi yang lebih luas. Model yang digunakan untuk menganalisis data tersebut menggunakan metode *time series* yaitu ARIMA dan SARIMA dengan hasil teknik analisis berdasarkan nilai dari RMSE & MAE.

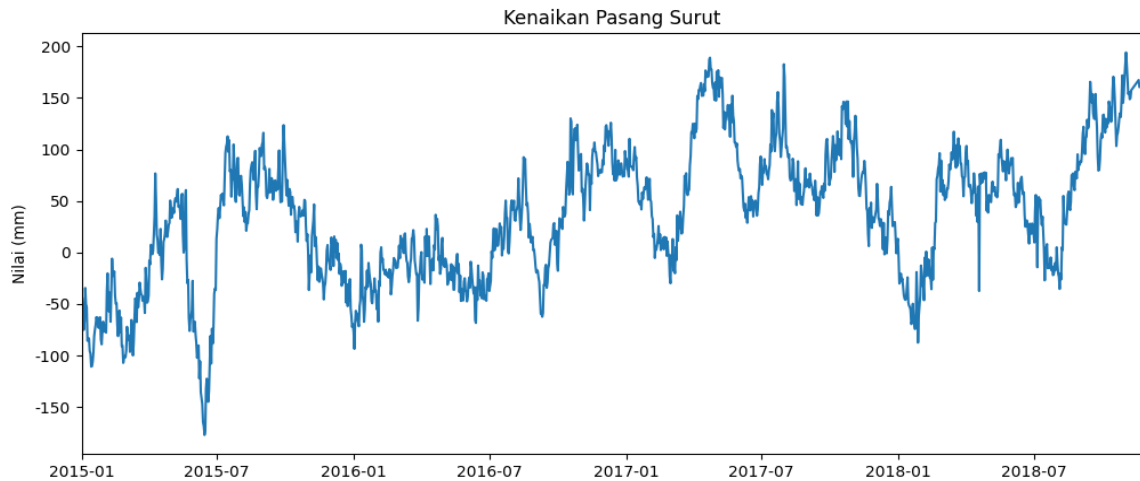
Pengumpulan data menggunakan metode studi pustaka yaitu pengambilan data yang di unduh langsung di web Pushidrosal. Data yang di salin berupa data kenaikan tinggi permukaan air atau gelombang beserta dengan data jam, tanggal, bulan dan tahun.

Analitik deskriptif membantu dalam mengekstraksi nilai akurasi tertinggi melalui algoritma *time series* untuk membangun dan menganalisis data real-time dan historis untuk mengekstrak wawasan pendekatan masa depan. Algoritma yang digunakan yaitu ARIMA dan SARIMA dalam mengimplementasikan data perubahan tinggi gelombang muka air laut di Jakarta Utara.

4. HASIL DAN PEMBAHASAN

4.1. Identifikasi Model

Pola *time series* tinggi gelombang laut Jakarta Utara pada bulan Januari tahun 2015 hingga bulan Desember 2020 ditunjukkan pada gambar.




Gambar 2. Pola Time Series

Berdasarkan gambar 2, menunjukkan bahwa puncak tinggi gelombang berada pada bulan November tahun 2018. Dapat diketahui, dalam algoritma ARIMA maupun SARIMA data harus stasioner. Data dapat dikatakan stasioner apabila memiliki pola yang konstan dari waktu ke waktu. Jika *time series* tidak stasioner, maka prediksi akan menyimpang dari nilai aslinya dan akan menimbulkan kesalahan. Dalam pengujian stasioneritas dilakukan tes menggunakan *Dickey Fuller Test*:

Ho: diasumsikan sebagai data tidak stasioner

Ha: diasumsikan sebagai data stasioner

Tolak Ho apabila diperoleh $p\text{-value} < \alpha (0,05)$



Gambar 3. Dickey-Fuller Test

Tabel 1. *Dickey-Fuller Test*

Dickey-Fuller Test:	Result
Test Statistic:	-3.35
p-value:	0.01
#Lags Used:	22.000000
Number of Observations Used:	1073.000000
Critical Value (1%):	-3.43
Critical Value (5%):	-2.86
Critical Value (10%):	-2.56

Setelah di uji stasioner menunjukkan bahwa nilai $p\text{-value} (0,01) < \alpha (0,05)$, maka Ho diterima. Jadi, data memiliki keadaan yang sudah stasioner.

4.2. Modelling

4.2.1. ARIMA

Dalam analisis awal dengan model ARIMA, kita mencoba beberapa kombinasi parameter p , d , dan q untuk mendapatkan model terbaik. Dalam kasus penelitian ini kita menggunakan `pdmarima` untuk melakukan otomatisasi model permutasi. Pada tahap ini kita melakukan identifikasi model yang bertujuan untuk menentukan parameter $p(P)$, $d(D)$ dan $q(Q)$ untuk ARIMA serta SARIMA. Adapun beberapa metodologi yang berguna dalam penentuan parameter penelitian ini memutuskan untuk menggunakan plot ACF dan PACF. Model parameter ini memiliki keunggulan dalam diferensiasi korelasi antar satuan data poin yang berguna dalam memperkirakan nilai kuat antara korelasi baik secara penuh maupun partial. Hal tersebut dapat memberikan informasi yang cermat dari grafik korelasi (ACF dan PACF) dengan sebaik mungkin, sehingga dalam penentuan parameter dapat di tentukan dengan optimal sesuatu dengan kriteria data, Parameternya sendiri ditentukan dengan mengevaluasi Informasi Akaike Kriteria (AIC), Log-kemungkinan fungsi ($\log L$) dan Kriteria Informasi Bayesian (BIC). Urutan model telah ditentukan sesuai dengan minimum treshold sesuai dengan data dan model yang digunakan. Model yang memiliki nilai minimum AIC, BIC dipilih sebagai yang terbaik. Sebanyak 16 model ARIMA yang berbeda dianggap bervariasi p , d & q dari 1 sampai 3 untuk simulasikan dalam mengetahui nilai AIC dan BIC. Skenario yang digunakan dalam melakukan analisis ACF dan PACF digunakan data poin per satuan hari selama 5 dengan 1427 data point. Hasilnya seperti pada gambar dibawah menunjukkan bahwa model dengan parameter (2,1,2) menunjukkan nilai terbaik dalam simulasi dengan nilai Akaike Kriteria (AIC), Log-kemungkinan fungsi ($\log L$) & Kriteria Informasi Bayesian (BIC) yang terendah.

Tabel 2. Parameter ARIMA terbaik

Model	logL	AIC	BIC	RMSE	MAE	MAPE	TIME
1.ARIMA(2,1,2)	4.20E+03	8.82E+03	8.83E+03	436	156	0.179	0,54
2.ARIMA(0,2,1)	4.40E+03	8.84E+03	8.83E+03	735	661	0.412	2
3.ARIMA(2,2,2)	4.30E+03	8.86E+03	8.83E+03	567	434	0.721	5,2
4.ARIMA(3,2,3)	4.40E+03	8.85E+03	8.83E+03	635	541	0.672	3,4
5.ARIMA(3,2,4)	4.50E+03	8.84E+03	8.83E+03	735	661	0.782	1.2

4.2.2. SARIMA

Sedangkan dalam menenentukan nilai Seasonal-Arima (Sarima) penelitian ini menggunakan pendekatan yang sama dengan mengetahui nilai ACF, PACF & *Seasonality*. Dengan parameternya sendiri ditentukan dengan mengevaluasi Informasi Akaike Kriteria (AIC), Log-kemungkinan fungsi ($\log L$) dan Kriteria Informasi Bayesian (BIC) serta output model evaluation. Sedangkan urutan permutasi parameter $(p,d,q)(P,D,Q)S$ telah ditentukan sesuai dengan minimum treshold sesuai dengan data dan model yang digunakan. Model yang memiliki nilai minimum AIC, BIC dipilih sebagai yang terbaik. Sebanyak 16 model ARIMA yang berbeda dianggap bervariasi p , d & q dari 1 sampai 3 untuk simulasikan untuk mengetahui nilai AIC dan BIC. Skenario yang digunakan dalam melakukan analisis ACF dan PACF digunakan data poin per satuan hari selama 5 dengan 1427 data point. Hasilnya seperti pada gambar dibawah menunjukkan bahwa model dengan parameter (5,1,4) menunjukkan nilai terbaik dalam simulasi dengan nilai Akaike Kriteria (AIC), Log-kemungkinan fungsi ($\log L$) & Kriteria Informasi Bayesian (BIC) yang terendah.

Tabel 3. Parameter SARIMA terbaik

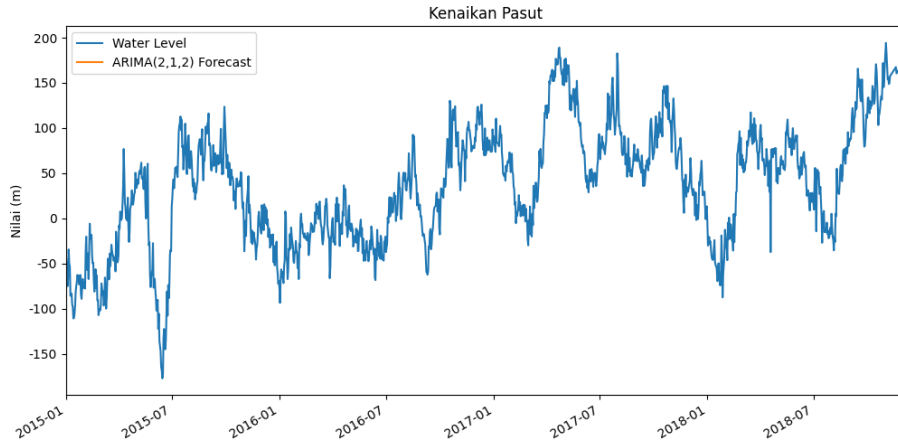
Model	logL	AIC	BIC	RMSE	MAE	MAPE	TIME
1.SARIMA(5,1,4) (0 1 1)5	4.40E+03	6.24E+03	8.83E+03	235	215	0.12	2
2.SARIMA(2,1,2) (1,1 ,1)5	4.20E+03	6.87E+05	8.83E+03	316	345	0.79	0,54
3.SARIMA(2,2,2) (2, 1, 1)5	4.30E+03	6.86E+03	8.83E+03	376	543	0.821	5,2
4.SARIMA(3,2,3) (4, 1, 1)5	4.40E+03	8.75E+03	8.83E+03	555	752	0.872	3,4
5.SARIMA(3,2,4) (3,2,2)5	4.50E+03	8.84E+03	8.83E+03	765	878	0.895	1.2

4.2.3. Model Fitting

Diantara lima parameter model yang berbeda kita melatih datanya dengan total sampel sebanyak 1425 data poin yang di pisah menjadi 75% data latih dan 25% data uji. Model dilatih menggunakan data pelatihan (1405 data poin) dan estimasi parameter yang sesuai dilakukan untuk masing-masing model. Uji-

Q Ljung-Box dilakukan dengan menggunakan pmdarima untuk semua autokorelasi residual. Residual diperiksa untuk setiap korelasi yang tersisa menggunakan ACF & PACF hasilnya menunjukkan bahwa permutari model parameter arima terbaik adalah ARIMA (2,1, 2) dengan nilai parameter terbaik sedangkan untuk pendekatan arima adalah (5,1,4).

4.2.4. Model Prediksi




Gambar 4. Prediksi ARIMA

Berdasarkan uji metode yang dilakukan terhadap model ARIMA, Hasil untuk pendekatan secara Auto Regresive Integrated Moving Averaged (ARIMA) dengan skenario permutasi parameter model p,d,q (2, 1, 2). Menunjukkan nilai peramalan yang sangat baik dengan nilai model evaluation RMSE & MAE yang baik secara berturut-turut yaitu sebesar 2,14 & 4,18. Dengan nilai prediksi dan nilai actual dari data yang diprediksi memiliki margin yang tipis sebagai berikut:

Tabel 4. Hasil Prediksi ARIMA

No	Time	Prediksi	Aktual
1	01-2019	155.9866933	155.84
2	07-2019	162.102526	162.4
3	01-2021	161.7737513	163.4
4	07-2021	161.8036599	161.4
5	01-2022	162.2386675	160.4
6	07-2022	162.2386675	163.3
7	01-2023	161.2386675	163.8

Bisa dilihat berdasarkan table diatas, nilai prediksi menunjukkan margin yang kecil terhadap nilai actual. Hal tersebut menandakan bahwa model sudah dengan baik melakukan peramalan secara timeseries menggunakan metode ARIMA. Hal tersebut dapat terjadi karena data yang bersifat stasioner dengan distribusi yang relative normal serta pengaruh musiman yang cenderung rendah. ARIMA Sendiri meramalkan kenaikan sebesar 8 cm selama kurun waktu 4 tahun terkahir dengan nilai kepercayaan sebesar 96,80%. Sedangkan Untuk dapat memastikan kita dapat melihat hasil prediksi dari pendekatan SARIMA.



Gambar 5. Prediksi SARIMA

Berdasarkan uji metode yang dilakukan terhadap model Seasonal-ARIMA (SARIMA), Hasil untuk pendekatan secara Seasonal Auto Regresive Integrared Moving Averaged (SARIMA) dengan skenario permutasi parameter model p,d,q (5, 1, 4). Menunjukkan nilai peramalan yang cukup baik dengan nilai model evaluation RMSE & MAE yang baik secara berturut-turut yaitu sebesar 4,52 & 8,18. Dengan nilai prediksi dan nilai actual dari data yang diprediksi memiliki margin sebagai berikut:

Tabel 5. Hasil Prediksi SARIMA

No	Time	Prediksi	Aktual
1	01-2019	152.9866933	155.84
2	07-2019	158.102526	162.4
3	01-2021	156.7737513	163.4
4	07-2021	155.8036599	161.4
5	01-2022	165.2386675	160.4
6	07-2022	167.2386675	164.3
7	01-2023	160.2386675	165.5

Berdasarkan hasil peramalan diatas menggunakan metode SARIMA menunjukkan nilai prediksinya sudah cukup baik namun tidak sebaik ketika menggunakan ARIMA. Hal tersebut dapat disimpulkan terjadi karena data yang digunakan memiliki karakteristik yang non-seasonal yang berarti memiliki pengaruh musiman yang kecil atau bahkan relative tidak ada. Hal tersebut menyebabkan model ARIMA memiliki nilai prediksi sedikit lebih baik dibandingkan dengan SARIMA. Secara keseluruhan arima memprediksi kenaikan muka air laut sebesar 10 cm dalam kurun waktu waktu 4 tahun terakhir dengan nilai kepercayaan sebesar 92.78%.

5. KESIMPULAN DAN SARAN

Hasil penelitian dapat disimpulkan bahwa model ARIMA & SARIMA yang dibuat untuk memprediksi tingkat kenaikan muka air laut di memiliki tingkat performa yang sangat baik dalam meramalkan kemungkinan terjadinya kenaikan muka air laut dengan prediksi yang sangat baik yaitu nilai *lower confidence level* sebesar 92.78% dan *upper confidence level* sebesar 98.80% dengan estimasi kenaikan muka air laut selama 4 tahun terakhir adalah 8-10 cm. Selain itu ketika di komparasi model ARIMA memiliki nilai yang lebih baik dibandingkan dengan SARIMA hal tersebut didasari pada data yang memiliki keterikatan kecil dengan pengaruh dari musiman atau seasonality. Selain itu secara ekologi terdapat ancaman nyata kenaikan muka air laut. Dengan kenaikan maksimum diperkirakan sebesar 8 sentimeter perlu adanya upaya untuk dapat menanggulangi permasalahan tersebut agar tidak menjadi kerugian baik secara ekologi, ekonomi dan sosial budaya bagi masyarakat sekitar, salah satunya adalah dengan melakukan revitalisasi dan pengelolaan tata ruang yang sesuai dengan kapasitas adaptif dari

lingkungan agar degradasi ekologi yang terjadi dapat diminimalisir dan dampak kenaikan air laut bisa ditekan.

Ucapan Terima Kasih

Saya ucapkan terima kasih sebesar-besarnya kepada

- Luthfi Anzani, M.Si. sebagai Pembimbing I, yang dengan tekun memberikan bimbingan ilmiah melalui berbagai pengarahan, sharing, dan usul/saran yang cemerlang.
- Wildan Afrizal, M.Kom. selaku Pembimbing II, yang juga dengan tekun memberikan bimbingan ilmiah melalui berbagai pengarahan, sharing, dan usul/saran yang yang dibderikan.

6. DAFTAR PUSTAKA

- [1] Berlinditya, B., & Noeryanti. (2019) Pemodelan Time Series Dalam Peramalan Jumlah Pengunjung Objek Wisata di Kabupaten Gunung Kidul Menggunakan Metode ARIMAX Efek Variasi Kalender. *Jurnal Statistika Industri dan Komputasi*, Vol 4 (1), 81–88.
- [2] Danukusumo, K. P. (2017). Implementasi Deep Learning Menggunakan CNN untuk Klasifikasi Citra Candi Berbasis GPU. *Jurnal Teknik Informatika*, Vol 2 (1), 6-13.
- [3] F. Nur Hadiansyah. (2017) Prediksi Harga Cabai dengan Menggunakan pemodelan Time Series ARIMA. *Indonesia Journal of Computing*, vol 2 (1), 71-78.
- [4] James, S. C., Yushan, Z., & O'Donncha, F. (2018). A Machine Learning Framework to Forecast Wave Conditions. *Coastal Engineering*, Vol 137, 1-10.
- [5] Kafara, Zaenab, Francis Y. Rumlawang, and Lexy J. Sinay. 2017. "Peramalan Curah Hujan Dengan Pendekatan Seasonal Autoregressive Integrated Moving Average (Sarima)." *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, Vol 11(1), 63–74.
- [6] Kuswartomo, Sulistiya, B. N., Isnugroho, & Fatchan, A. K. (2021). Prediksi Tinggi Gelombang Berdasarkan CERC (SPM 1984) Di Pantai Baru, Bantul, Daerah Istimewa Yogyakarta. *Dinamika Teknik Sipil*, Vol 7(1), 1-7.
- [7] Mahesh, B. (2018). Machine Learning Algorithms - A Review. *International Journal of Science and Research*, Vol 9 (1), 381-386.
- [7] Nurhidayat, A., Asmunin, A., & Suyatno, D. F. (2021). Prediksi Kinerja Akademik Mahasiswa Menggunakan Machine Learning dengan sequential Minimal Optimization Untuk Pengelola Program Studi. *Journal of Information Engineering and Educational Technology*, Vol 5 (2), 7-16.
- [8] Ondara, K. dan H. Semeidi. (2017). Karakteristik Gelombang Pecah dan Analisis Transpor Sedimen di Perairan Teluk Kendari. *Jurnal Ilmu dan Teknologi Kelautan Tropis*. Vol 9 (2), 585– 596.
- [9] Putri, S., & Sofro, A. (2022). Peramalan Jumlah Keberangkatan Penumpang Pelayaran Dalam Negeri di Pelabuhan Tanjung Perak Menggunakan Metode ARIMA dan SARIMA. *Jurnal Ilmiah Matematika*, Vol 10 (1), 61-67.
- [10] Raharja, M. A., & Astra, I. T. (2018). Prediksi Ketinggian Gelombang Laut Menggunakan Metode Backpropagation Pada Pantai Lebih Gianyar. *Jurnal Ilmu Komputer*, Vol 11 (1), 19-26.
- [11] Rashed, Yasmine, Hilde M., Eddy V., & Thierry V. (2017). Short-Term Forecast of Container throughout: An ARIMA-Intervention Model for the Port of Antwerp. *Maritime Economics and Logistics* Vol 19(4), 749–64.
- [12] Risandi, J., s, widodo, & D, C. (2021). Prediksi Gelombang Ekstrim di Kepulauan Seribu untuk Aplikasi Kelautan dan Perikanan. *Jurnal Riset Jakarta*, Vol 14 (2), 51-56.
- [13] Siregar, G. R., Adiningsih, S., & Heryanto, Y. (2020). Easywae Untuk Peramalan Data Gelombang Laut Berbasis Pemrograman Python Dengan Metode SVERRUP, MUNK and BRETSCHNEIDER (SMB) (Studi Kasus: Perairan Sungairade, Kalimantan Timur. *Jurnal Meteorologi dan Klimatologi Geofisika*, Vol 7 (1), 20-29.
- [14] Sutrisno, A. F., Rais, & Setiawan, I. (2021). Intervention Model Anlysis the Number of Domestic Passenger at Sultan Hasanuddin Airports. *Journal of Statistics*, Vol 1 (1), 41-49.
- [15] Unnikrishnan, Jyothi, & Kodakanallur K. S. (2016). Modelling the Impact of Government Policies on Import on Domestic Price of Indian Gold Using ARIMA Intervention Method." *International Journal of Mathematics and Mathematical Sciences* 2016.
- [16] Uswatun, K. (2019). Implementasi Metode Volume Hingga Pada Gelombang Air Laut di Perairan Selat Sunda. *Jurnal Matematika*, Vol 2 (1), 1-73.