

COMPARISON OF GARCH AND LSTM MODELS FOR PREDICTING SEA SURFACE TEMPERATURE VOLATILITY IN THE SOUTHERN WATERS OF JAVA

Perbandingan Model GARCH dan LSTM untuk Prediksi Volatilitas Suhu Permukaan Laut di Perairan Selatan Jawa

Oleh:

Arif Budiman¹, Evelyn Tan Eldisha Nawa¹, Farhiya Salsa Billa¹, M. Arkan Anzuye¹, Fitri Kartiasih^{2*}

¹Program Studi DIV Komputasi Statistik, Politeknik Statistika STIS, Indonesia

²Program Studi DIV Statistika, Politeknik Statistika STIS, Indonesia

*Korespondensi penulis: fkartiasih@stis.ac.id

ABSTRACT

Indonesia, as an archipelagic country with a maritime economic potential of US\$ 1.33 trillion per year, faces serious challenges due to climate change, particularly rising sea surface temperatures (SST) and marine heatwaves (MHW), which impact fisheries productivity and the stability of the Blue Economy. This study aims to predict SST volatility in the region through the development of a forecasting model that compares ARCH-GARCH and Long Short-Term Memory (LSTM) to model non-linear patterns and long-term dependencies. Oceanographic time series datasets were used to train and test the model's performance. The results show that the LSTM model has much higher accuracy than the ARCH-GARCH model in predicting SPL volatility, with lower error values and better ability to capture non-linear patterns and complex sea temperature dynamics. This study confirms that the LSTM approach is more suitable for use as an oceanographic forecasting model, thereby supporting the strengthening of the Blue Economy and the resilience of Indonesia's maritime sector.

Key words: *blue economy, sea surface temperature, GARCH, LSTM*

ABSTRAK

Indonesia sebagai negara kepulauan dengan potensi ekonomi maritim mencapai US\$ 1,33 triliun per tahun menghadapi tantangan serius akibat perubahan iklim, khususnya peningkatan suhu permukaan laut (SPL) dan kejadian *marine heatwaves* (MHW) yang berdampak pada produktivitas perikanan dan stabilitas *Blue Economy*. Penelitian ini bertujuan memprediksi volatilitas SPL di kawasan tersebut melalui pengembangan model peramalan yang membandingkan ARCH-GARCH dan Long Short-Term Memory (LSTM) untuk memodelkan pola non-linear serta dependensi jangka panjang. Dataset deret waktu oseanografi digunakan untuk melatih dan menguji performa model. Hasil penelitian menunjukkan bahwa model LSTM memiliki akurasi yang jauh lebih tinggi dibandingkan model ARCH-GARCH dalam memprediksi volatilitas SPL, dengan nilai error yang lebih rendah dan kemampuan lebih baik dalam menangkap pola non-linear dan dinamika suhu laut yang kompleks. Penelitian ini menegaskan bahwa pendekatan LSTM lebih layak digunakan sebagai model peramalan oseanografi, sehingga mendukung penguatan Ekonomi Biru dan ketahanan sektor maritim Indonesia.

Kata kunci: *blue economy, suhu permukaan laut, GARCH, LSTM*

PENDAHULUAN

Indonesia dikenal sebagai negara kepulauan terbesar di dunia dengan wilayah laut mencapai 6,4 juta km² serta posisi strategis di antara Samudera Hindia dan Pasifik. Letak geografis ini memberikan Indonesia peran penting dalam dinamika ekonomi global (Zulkifli *et al.* 2023). Sektor kelautan juga dipandang sebagai “garis depan baru” pembangunan nasional karena potensi ekonomi maritimnya yang besar, diperkirakan mencapai US\$ 1,33 triliun per tahun. Potensi tersebut sejalan dengan visi Indonesia sebagai poros maritim dunia dan penerapan konsep ekonomi biru (*blue economy*) (Zulkifli *et al.* 2023). *Blue economy* merupakan pendekatan pembangunan yang menekankan pemisahan antara pertumbuhan ekonomi dan kerusakan lingkungan, dengan tujuan menjaga keseimbangan antara kesejahteraan masyarakat dan kelestarian ekosistem laut (Rahmayanti *et al.* 2025). Dalam perspektif ini, keamanan maritim tidak hanya berfungsi sebagai penjaga kedaulatan, tetapi juga mendukung aktivitas ekonomi melalui penyediaan informasi oseanografi yang akurat atau *Maritime Domain Awareness* (MDA) (Voyer *et al.* 2018).

Meskipun demikian, keberlanjutan ekonomi biru di Indonesia khususnya pada sektor perikanan dan pariwisata bahari yang dipandang sebagai salah satu solusi menangani pendapatan menengah (*middle income trap*) yang sedang menghadapi tantangan besar akibat perubahan iklim global (Ayuningtyas & Muchlisoh, 2024). Pemanasan global telah menyebabkan meningkatnya suhu permukaan laut (*Sea Surface Temperature*) serta memicu fenomena ekstrem seperti *Marine Heatwaves* (MHW) (Anggraeni *et al.* 2025; Cheng *et al.* 2023; Reynolds *et al.* 2007). MHW merupakan kondisi pemanasan laut intens ketika suhu permukaan melebihi persentil ke-90 dari nilai normalnya (Hobday *et al.* 2016), dan secara global kejadian ini telah meningkat lebih dari 50% sejak awal abad ke-20 (Nguyen & Nguyena, 2017; Song *et al.* 2024). Frekuensi dan durasi MHW di Indonesia menunjukkan tren peningkatan yang signifikan pada periode 1982–2021, yang diperburuk oleh variabilitas iklim seperti *El Niño–Southern Oscillation* (ENSO) dan *Indian Ocean Dipole* (IOD) (Atmadipoera *et al.* 2020; Ningsih *et al.* 2023).

Laut selatan Jawa dipilih sebagai fokus penelitian karena memiliki karakteristik oseanografi yang sangat penting dan sensitif (Akhbar *et al.* 2018; Atman *et al.* 2017; Fadika *et al.* 2014; Wibisana *et al.* 2018). Wilayah ini merupakan titik panas (*hotspot*) MHW dengan intensitas dan durasi tertinggi di Indonesia, sekaligus menjadi kawasan *upwelling* terkuat yang mendukung produktivitas perikanan pelagis, terutama tuna (Syamsuddin *et al.* 2016; Zulkifli *et al.* 2023). Secara administratif, daerah ini berada dalam Wilayah Pengelolaan Perikanan Negara Republik Indonesia (WPPNRI) 573 yang memiliki nilai strategis tinggi. Dinamika oseanografi di Laut Selatan Jawa sangat dipengaruhi oleh ENSO dan IOD serta dicirikan oleh adveksi panas yang dominan. Kondisi tersebut menjadikan Laut Selatan Jawa sangat rentan terhadap perubahan iklim; MHW terbukti menghambat *upwelling* dan menurunkan kadar klorofil-a, yang berdampak langsung pada produktivitas ekosistem dan keberlanjutan ekonomi biru di wilayah tersebut. Oleh sebab itu, kemampuan dalam memprediksi volatilitas parameter oseanografi menjadi langkah mitigasi yang sangat diperlukan.

Penelitian sebelumnya telah berupaya melakukan pemodelan suhu laut untuk mengantisipasi anomali iklim. Oktaviani *et al.* (2021) meramalkan anomali SST (SSTA) di Samudera Hindia bagian barat Sumatra menggunakan pendekatan *Seasonal Autoregressive Integrated Moving Average* (SARIMA) yang dikombinasikan dengan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH). Hasil penelitian tersebut menunjukkan bahwa model GARCH mampu menangani data dengan varians residual tidak konstan (heteroskedastisitas) dan menghasilkan akurasi tinggi dengan MAPE 3,67%. Namun, pendekatan statistik seperti SARIMA memiliki keterbatasan dalam merepresentasikan pola non-linear dan hubungan jangka panjang yang umum dijumpai pada fenomena iklim ekstrem seperti MHW.

Penelitian ini bertujuan untuk memprediksi dinamika anomali suhu permukaan laut (*Sea Surface Temperature Anomaly/SSTA*) di perairan selatan Jawa melalui perbandingan model ARCH–

GARCH dan *Long Short-Term Memory* (LSTM). Dalam penelitian ini, volatilitas didefinisikan sebagai perubahan varians bersyarat (*conditional variance*) dari deret waktu SSTA. Pada pendekatan ARCH–GARCH, volatilitas dimodelkan secara eksplisit melalui *varians residual model mean*, sedangkan pada pendekatan LSTM, model dilatih untuk memprediksi deret waktu SSTA yang kemudian digunakan sebagai representasi dinamika volatilitas suhu permukaan laut. Pendekatan ini diharapkan mampu menyediakan informasi yang lebih akurat untuk mendukung sistem peringatan dini *marine heatwaves* serta pengelolaan sumber daya kelautan yang berkelanjutan.

METODE PENELITIAN

Data *Sea Surface Temperature* (SST) diperoleh dari website Physical Sciences Laboratory NOAA yang menyediakan data terkait cuaca, iklim, dan prediksi cuaca ekstrem. Penelitian ini menggunakan data rata-rata harian SST dari tahun 1995 hingga 2025 di wilayah Selatan Jawa (Lat -12 s.d -8, Lon 109 s.d 111). Rentang data harian selama 31 tahun ini dipilih merujuk pada definisi Marine Heatwaves (MHW) oleh Hobday *et al.* (2016), yang menyatakan bahwa pendeteksian anomali suhu ekstrem memerlukan periode baseline klimatologi minimal 30 tahun. Sesuai dengan rekomendasi Hobday *et al.* (2016), penelitian ini menggunakan definisi hierarkis di mana MHW ditentukan berdasarkan ambang batas persentil ke-90 dari data historis (klimatologi). Agar sebuah anomali suhu diklasifikasikan sebagai MHW, suhu tersebut harus bertahan di atas ambang batas selama minimal lima hari berturut-turut. Batasan durasi ini diterapkan untuk membedakan gelombang panas yang persisten dari lonjakan panas sesaat (*heat spikes*) yang berdurasi pendek (<5 hari), serta untuk menjaga konsistensi statistik dengan definisi gelombang panas pada atmosfer.

Data yang didapatkan dari sumber mengandung variabel tanggal dan rata-rata SST harian seluruh dunia. Data tersebut kemudian dilakukan *preprocessing* dengan melakukan *filter* pada koordinat yang sesuai dan menghitung rata-rata semua *pixel* di area kotak koordinat menjadi 1 nilai per hari lalu menggabungkan data harian selama 31 tahun tersebut menjadi 1 *file* dengan total 11.295 datum. Setelah itu dilakukan pendeteksian MHW dengan menghitung anomali dan *threshold* dengan periode baseline 1995-2025. Pendeteksian MHW, penentuan *threshold*, dan perhitungan rata rata klimatologi dilakukan dengan memanfaatkan *package* dari *library marine heatwaves* dari *github ecjoliver*.

Preprocessing data dilakukan untuk menormalisasi data mentah SST menjadi data SSTA yaitu data mentah dikurangi dengan rata-rata dari data mentah tersebut. Tujuan utama dari penggunaan data SSTA adalah :

- a) Menghilangkan sinyal musiman (*seasonality*): Data SST absolut biasanya memiliki pola musiman tahunan yang kuat (misalnya, lebih hangat di musim panas dan lebih dingin di musim dingin). Dengan mengurangi nilai rata-rata historis (normal musiman), anomali akan mengisolasi fluktuasi yang tersisa dari sinyal musiman tersebut.
- b) Menghilangkan tren jangka panjang: Anomali juga membantu mengabaikan variasi yang sangat lambat atau tren yang umum, sehingga memudahkan analisis terhadap sinyal periodik atau fluktuasi yang lebih kecil.

Setelah menghasilkan data SSTA, data tersebut dibagi dengan proporsi 80:20, dengan 80% data awal sebagai data training untuk melatih model pada LSTM dan 20% data sisanya digunakan untuk data testing. Data testing juga digunakan untuk model ARCH/GARCH dalam mencari metrik evaluasi model sebagai keterbandingan dengan model LSTM.

Pemodelan volatilitas pada penelitian ini dilakukan menggunakan pendekatan ARCH–GARCH untuk menangkap pola varians deret waktu SSTA yang berubah dari waktu ke waktu dan menunjukkan sifat heteroskedastisitas bersyarat. Model ARCH–GARCH digunakan untuk memprediksi deret waktu SSTA sekaligus mengestimasi volatilitasnya melalui *conditional variance* dari residual model mean,

sehingga menghasilkan prediksi nilai SSTA beserta estimasi volatilitas yang menyertainya. Data penelitian terlebih dahulu dibagi menjadi dua bagian, yaitu 80% sebagai data training dan 20% sebagai data testing. Pembagian ini bertujuan agar proses pembentukan model dilakukan menggunakan data historis, sedangkan evaluasi performa prediksi dilakukan secara *out-of-sample*, sehingga hasil peramalan lebih representatif dan tidak bias. Hasil prediksi model ARCH–GARCH selanjutnya dibandingkan dengan model *Long Short-Term Memory* (LSTM) yang dibangun menggunakan data dan target prediksi SSTA yang sama, sehingga evaluasi kedua pendekatan dilakukan pada objek prediksi yang identik.

Proses pemodelan diawali dengan pemeriksaan kestasioneran data melalui visualisasi pola ACF dan PACF serta uji formal *Augmented Dickey–Fuller* (ADF). Jika hasil pengujian menunjukkan bahwa data tidak stasioner pada level, maka dilakukan proses differencing hingga memenuhi karakteristik stasioner. Setelah data dinyatakan stasioner, langkah berikutnya adalah identifikasi struktur model mean menggunakan pendekatan Box–Jenkins. Kandidat model ARIMA dipertimbangkan berdasarkan pola autokorelasi serta hasil estimasi parameter pada data training.

Setelah model mean ditentukan, dilakukan pemeriksaan terhadap residual untuk mengetahui keberadaan efek ARCH menggunakan uji ARCH–LM. Apabila hasil uji menunjukkan indikasi heteroskedastisitas bersyarat, maka pemodelan dilanjutkan dengan estimasi model varians ARCH, GARCH, atau turunannya. Sejumlah model alternatif diestimasi dan dibandingkan berdasarkan nilai *Akaike Information Criterion* (AIC), kecukupan diagnostik, serta signifikansi parameter untuk menentukan model volatilitas terbaik.

Model mean dan model varians yang terpilih kemudian digabungkan dan diestimasi ulang sehingga membentuk model akhir. Model ini selanjutnya digunakan untuk melakukan peramalan terhadap data testing. Evaluasi performa prediksi dilakukan menggunakan ukuran kesalahan seperti *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE), sehingga kemampuan model dalam menghasilkan prediksi dapat dinilai secara objektif (Engle, 1982; Fauzan *et al.*, 2024; Hilal *et al.*, 2024; Suhendi *et al.*, 2024).

Pada pendekatan LSTM, variabel yang diprediksi adalah deret waktu SSTA. Berbeda dengan model ARCH–GARCH yang secara eksplisit memodelkan volatilitas melalui conditional variance dari residual model mean, LSTM tidak memodelkan varians secara langsung (Gers *et al.* 2000; Hochreiter & Schmidhuber, 1997). Oleh karena itu, LSTM digunakan untuk mempelajari pola non-linier dan ketergantungan jangka panjang pada deret waktu SSTA sehingga mampu menghasilkan prediksi perubahan anomali suhu dari waktu ke waktu. Fluktuasi hasil prediksi SSTA tersebut selanjutnya digunakan sebagai representasi dinamika volatilitas suhu permukaan laut dan dibandingkan dengan hasil model ARCH–GARCH menggunakan metrik evaluasi yang sama (RMSE, MAE, MAPE, dan MSE).

Penelitian ini menggunakan algoritma LSTM dengan memanfaatkan bantuan bahasa pemrograman python untuk melakukan pencarian model terbaik dan forecasting. Tools yang digunakan dalam algoritma LSTM ini adalah Keras untuk membuat jaringan saraf tiruan (LSTM), melakukan training, dan prediksi, Scikit-Learn untuk menghitung evaluasi model terbaik, Math untuk menghitung akar kuadrat, dan Numpy untuk Menangani operasi matriks dan *array* data angka.

Untuk mendapatkan model dengan performa prediksi terbaik, penelitian ini menerapkan skenario pengujian parameter (*hyperparameter tuning*) pada arsitektur LSTM. Variabel parameter yang diujikan difokuskan pada dua komponen utama yang mempengaruhi kemampuan belajar model, yaitu jumlah unit neuron pada *hidden layer* dan jumlah iterasi pelatihan (*epoch*). Implementasi pemodelan dilakukan menggunakan *library Keras (TensorFlow)* pada lingkungan *Python*. Skenario eksperimen dirancang dengan mengombinasikan variasi parameter sebagai berikut:

- 1) Variasi Jumlah Neuron: 50 dan 100 neuron. Jumlah neuron menentukan kapasitas memori model dalam menangkap pola data yang kompleks.

- 2) Variasi Jumlah Epoch: 50 dan 100 epoch. Jumlah *epoch* menentukan seberapa banyak model melihat keseluruhan data latih untuk meminimalkan *loss function*.

Untuk mengevaluasi pengaruh masing-masing parameter terhadap kinerja model, empat skenario LSTM dibangun berdasarkan kombinasi jumlah neuron dan *epoch* sebagaimana disajikan pada

Table 1. *Long Short-Term Memory (LSTM) model scenario*

Tabel 1. Skenario model *Long Short-Term Memory* (LSTM)

Skenario	Jumlah Neuron	Jumlah Epoch
Model 1	50	50
Model 2	50	100
Model 3	100	50
Model 4	100	100

Proses pelatihan menggunakan fungsi kerugian (*loss function*) *Mean Squared Error* (MSE) untuk mengoptimalkan bobot model. Evaluasi performa dari setiap skenario diukur menggunakan metrik RMSE (*Root Mean Square Error*), MAE (*Mean Absolute Error*), dan MAPE (*Mean Absolute Percentage Error*). Model dengan nilai *error* terendah akan dipilih sebagai model terbaik yang kemudian digunakan untuk melakukan prediksi akhir pada data uji (*testing data*). Berdasarkan hasil pelatihan sementara, pemilihan model terbaik ditentukan secara otomatis oleh sistem ketika nilai RMSE dan MAE mencapai titik minimum, yang mengindikasikan bahwa model memiliki tingkat penyimpangan terkecil terhadap data aktual.

HASIL DAN PEMBAHASAN

Deskripsi Data

Pola SSTA selama periode 1996–2025 menunjukkan adanya *volatility clustering* yang jelas, terutama pada periode 1997–1998 dan 2015–2016 sebagaimana ditunjukkan pada **Figure 1**, ketika fluktuasi suhu meningkat secara signifikan. Periode tersebut bertepatan dengan kejadian *El Niño* yang diketahui berkontribusi terhadap peningkatan suhu permukaan laut secara ekstrem serta memperburuk kondisi kekeringan di berbagai wilayah. Pola ini mengindikasikan adanya variansi yang tidak konstan dalam deret waktu, sehingga memberikan justifikasi empiris untuk penggunaan model ARCH/GARCH dalam analisis selanjutnya.




Figure 1 SSTA data Visualisation

Gambar 1 Visualisasi data SSTA

Statistik deskriptif variabel SSTA yang dirangkum dalam **Table 2** berdasarkan 11.295 observasi menunjukkan nilai rata-rata sebesar 0,0524 yang mengindikasikan kecenderungan sedikit positif terhadap kondisi suhu normal. Rentang nilai yang cukup lebar, dengan maksimum +2,87 °C dan minimum -2,35 °C, mencerminkan adanya kejadian ekstrem baik pada fase pemanasan maupun pendinginan laut. Hal ini diperkuat oleh nilai kurtosis sebesar 3,37 yang mengindikasikan distribusi leptokurtik, serta hasil uji Jarque–Bera yang signifikan, yang menunjukkan bahwa distribusi data tidak mengikuti distribusi normal.

Table 2. *Statistical summary of the SSTA variable*

Tabel 2. Ringkasan statistik variable SSTA

Ukuran	SSTA
Mean	0,052428
Median	0,050836
Maximum	2,866878
Minimum	-2,34913
Std. Dev.	0,68659
Skewness	0,161647
Kurtosis	3,370259
Jarque-Bera	113,7078
Probability	0,000000
Sum	592,1783
Sum Sq. Dev.	5324,050
Observations	11295

Deteksi kejadian *Marine Heat Waves (MHW)* yang ditampilkan pada **Figure 2** menunjukkan bahwa peristiwa ekstrem terjadi pada sekitar Oktober–November 2025, ketika anomali suhu melampaui ambang batas ekstrem yang ditandai oleh garis putus-putus berwarna hijau dan berlangsung selama lebih dari lima hari berturut-turut, sehingga diklasifikasikan sebagai MHW dan ditandai dengan area berwarna merah pada grafik deteksi. Temuan ini mengonfirmasi bahwa peristiwa tersebut memenuhi kriteria intensitas dan durasi sebagai kejadian suhu ekstrem yang signifikan dalam periode pengamatan. Konsistensi hasil ini juga terlihat dari karakteristik statistik variabel SSTA (**Table 2**) yang mencakup 11.295 observasi selama periode 1995–2025, dengan intensitas maksimum mencapai +2,86°C dan minimum -2,35°C. Selain itu, nilai kurtosis sebesar 3,37 (lebih besar dari 3) menunjukkan distribusi leptokurtik, yang mengindikasikan bahwa kejadian ekstrem, baik pemanasan maupun pendinginan, terjadi lebih sering dibandingkan distribusi normal, sehingga memperkuat bukti adanya intensifikasi kejadian ekstrem pada suhu permukaan laut.

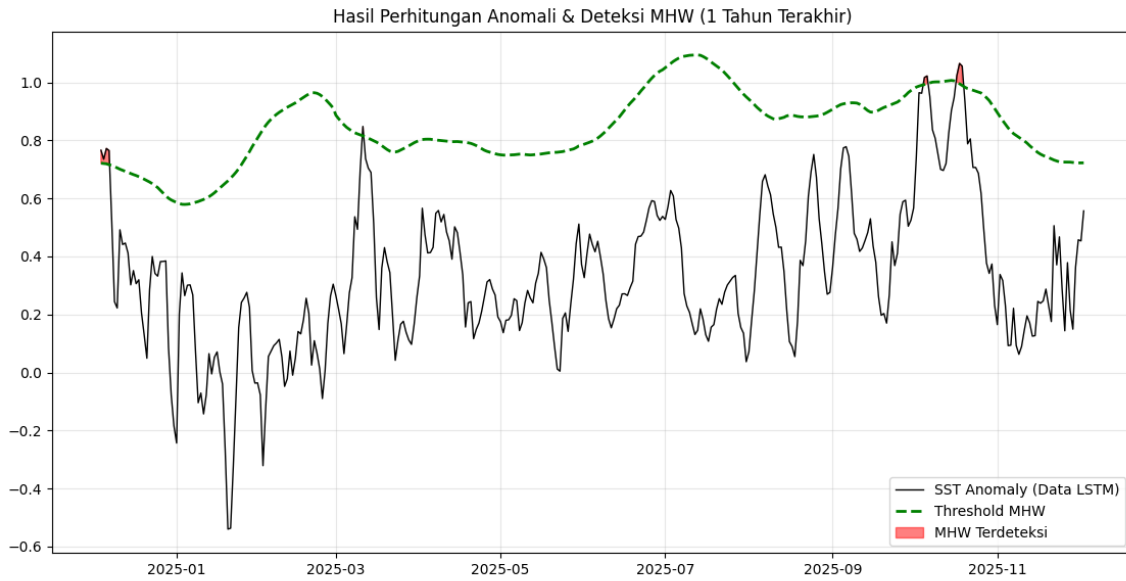


Figure 2 Calculation of anomalies and detection of MHW

Gambar 2 Perhitungan anomali dan deteksi MHW

Berdasarkan **Figure 2** tersebut terlihat bahwa kejadian *Marine Heat Waves (MHW)* terjadi pada rentang sekitar Oktober hingga November 2025, ketika anomali suhu menembus ambang batas ekstrem yang ditunjukkan oleh garis putus-putus berwarna hijau dan berlangsung selama lebih dari lima hari berturut-turut, sehingga diwarnai merah pada area deteksi. Temuan ini mengonfirmasi hasil deteksi sebelumnya yang menunjukkan bahwa peristiwa tersebut memenuhi kriteria intensitas dan durasi sebagai MHW, sehingga dapat diklasifikasikan sebagai kejadian suhu ekstrem yang signifikan dalam periode pengamatan.




Figure 3 Correlogram at the level

Gambar 3 Correlogram di level

Berdasarkan **Figure 3** dapat dilihat bahwa correlogram PACF *spike* di lag 1 sehingga model yang sesuai adalah AR(1). Dilihat dari ACF tidak stasioner, namun terlihat dari PACF stasioner, sehingga keadaan tersebut menandakan adanya AR(1) dan MA(0).

Table 3. ARCH modelling results

Tabel 3. Hasil pemodelan ARCH

Model	AIC	<i>p-value</i> uji F	<i>Adj Rsquare</i>
AR(2)	-6502,958	0 (sig)	0.9792
AR(1)	-7072,263	0 (sig)	0.9803

Hasil identifikasi model mean beserta nilai AIC, *p-value* uji F, dan adjusted R-square untuk masing-masing kandidat model disajikan pada Tabel 3. Berdasarkan analisis nilai AIC, terpilih model terbaik dengan nilai AIC terendah yaitu AR(2) dengan persamaan sebagai berikut:

Terlihat dari analisis AIC, terpilih model terbaik dengan AIC terendah yaitu AR(3) dengan persamaan yaitu:

$$SSTA_t = 0.3554 + 1.2093(SSTA_{t-1}) - 0.2221(SSTA_{t-2}) + \varepsilon_t$$

Uji ARCH dilakukan untuk mendeteksi apakah residual dari model mean (AR(1)) memiliki varians yang tidak konstan (*heteroskedastic*). Karena nilai *p-value* = 0.000 < 0.05, maka H_0 ditolak. Temuan ini menunjukkan bahwa residual dari model AR(1) mengandung efek ARCH, sehingga model mean saja tidak cukup untuk menjelaskan volatilitas residual. Sebagaimana ditunjukkan pada Tabel 3, seluruh kandidat model memiliki nilai *p-value* uji F yang signifikan, namun pemilihan model terbaik dilakukan berdasarkan nilai AIC terendah sebagai indikator keseimbangan antara kesesuaian model dan kompleksitasnya.

Analisis Model ARCH/GARCH

Setelah teridentifikasi adanya efek ARCH, tahap selanjutnya adalah membangun beberapa kandidat model volatilitas dari keluarga ARCH/GARCH, yang meliputi model GARCH, EGARCH, dan TGARCH dengan berbagai kombinasi orde. Setiap model kemudian dievaluasi untuk menentukan model yang paling sesuai dalam merepresentasikan dinamika volatilitas data. Evaluasi dilakukan berdasarkan beberapa kriteria, yaitu keberadaan efek asimetri (*asymmetric effect*) atau *threshold effect* yang menunjukkan apakah guncangan positif dan negatif memberikan dampak yang berbeda terhadap volatilitas, hasil uji heteroskedastisitas untuk memastikan bahwa model mampu mengatasi heteroskedastisitas yang terdeteksi pada data, serta nilai *Akaike Information Criterion* (AIC) sebagai dasar pemilihan model terbaik. Kriteria AIC digunakan untuk menilai keseimbangan antara tingkat kesesuaian model terhadap data dan kompleksitas model yang digunakan, dimana model dengan nilai AIC yang lebih rendah dianggap lebih efisien dan memiliki kemampuan representasi yang lebih baik.

Berdasarkan hasil estimasi, model TGARCH(1,1) menghasilkan nilai AIC paling rendah, yang menunjukkan bahwa model tersebut memiliki *goodness-of-fit* terbaik di antara kandidat yang diestimasi (lihat **Table 4**). Namun, hasil uji heteroskedastisitas pada residual masih menunjukkan nilai *p-value* < 0,05, sehingga residual model masih mengandung efek ARCH yang menandakan bahwa model belum mampu menangkap seluruh pola volatilitas pada data. Kondisi ini mengindikasikan bahwa meskipun model memiliki kecocokan yang baik terhadap data, asumsi diagnostik belum terpenuhi sehingga model belum layak digunakan sebagai model akhir untuk peramalan. Oleh karena itu, model TGARCH(1,1) tidak dipilih.

Table 4. Estimation results for ARCH/GARCH model candidates**Tabel 4.** Hasil estimasi kandidat model ARCH/GARCH

Model	Assymetric/Threshold	p-value (Uji Heteroskedastisitas)	AIC
AR(2) - EGARCH (1,1)	0	< 0.05	-0.749941
AR(2) - EGARCH (1,0)	0	0.3	-0.66732
AR(2) - EGARCH (1,0)	1	0.7	-0.67469
AR(2) - EGARCH (1,1)	1	< 0.05	-0.79963
AR(2) - GARCH (1,0)	0	0.0803	-0.6656
AR(2) - GARCH (1,1)	0	< 0.05	-0.80059
AR(2) - TGARCH (1,0)	1	0.18	-0,67243
AR(2) - TGARCH (1,1)	1	< 0.05	-0.801

Sebaliknya, model AR(2)–EGARCH(1,0) dipilih sebagai model terbaik karena telah memenuhi uji diagnostik dengan nilai *p-value* > 0,05, yang menunjukkan bahwa efek ARCH pada residual telah berhasil dieliminasi, serta tetap memiliki nilai AIC yang relatif rendah. Hal ini sejalan dengan prinsip pemodelan volatilitas yang menyatakan bahwa model terbaik tidak hanya ditentukan oleh nilai informasi kriteria (AIC/BIC), tetapi juga harus memenuhi uji diagnostik sehingga residual tidak lagi mengandung efek ARCH dan model mampu merepresentasikan dinamika volatilitas secara memadai (Engle, 1982; Bollerslev, 1986). Dengan demikian, pemilihan model dalam penelitian ini tidak hanya didasarkan pada kemampuan model menyesuaikan data (*goodness-of-fit*), tetapi juga pada terpenuhinya asumsi diagnostik, sehingga model yang dipilih lebih valid, stabil, dan andal untuk analisis maupun peramalan volatilitas.

$$\log(\sigma_t^2) = -3.666005 + 0.220419 \left| \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right| - 0.130534 \frac{\varepsilon_{t-1}}{\sigma_{t-1}}$$

Dimana σ_t^2 adalah *conditional variance*, ε_{t-1} adalah residual periode sebelumnya, σ_{t-1} merupakan akar kuadrat dari periode sebelumnya (standar deviasi), $\frac{\varepsilon_{t-1}}{\sigma_{t-1}}$ adalah *standardized residual*/suku asimetris, serta $\left| \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right|$ merupakan suku ARCH. Konstanta (ω): -3.666 adalah dasar volatilitas jangka panjang dalam bentuk logaritma. Efek ARCH/Magnitude (α): 0.22042 menunjukkan dampak *shock*, semakin positif maka semakin besar *shock* yang terjadi dan volatilitas akan semakin meningkat. Efek Lverage/Asimetris (γ): -0.1305 menunjukkan arah *shock*. Koefisien bernilai negatif berarti jika terjadi shock negatif ($\varepsilon_{t-1} < 0$) maka volatilitas akan naik lebih tinggi dibandingkan jika terjadi shock positif.

Analisis LSTM

Berdasarkan metrik evaluasi model yang dilakukan, Model 3 (Neuron = 100, Epoch = 50) terpilih sebagai model terbaik dengan nilai RMSE sebesar 0,1103, MAE sebesar 0,0791, MAPE sebesar 83,87%, dan MSE sebesar 0,0122, yang merupakan nilai terendah dibandingkan model lainnya. Nilai RMSE, MAE, dan MSE yang relatif kecil menunjukkan bahwa secara absolut selisih antara hasil prediksi dan nilai aktual cenderung rendah. Dengan kata lain, model mampu mengikuti pola umum data dengan tingkat kesalahan yang relatif terbatas. Selain itu, perbedaan nilai *error* antar konfigurasi model juga tidak terlalu besar, yang mengindikasikan bahwa perubahan jumlah *neuron* dan *epoch* hanya memberikan pengaruh marginal terhadap peningkatan kinerja model.

Nilai MAPE yang diperoleh menunjukkan pola yang berbeda dibandingkan RMSE, MAE, dan MSE karena metrik ini mengukur kesalahan dalam bentuk persentase terhadap nilai aktual. Oleh karena itu, MAPE cenderung lebih sensitif terhadap variasi nilai aktual pada data deret waktu. Temuan ini menunjukkan pentingnya menginterpretasikan kinerja model secara komprehensif dengan

mempertimbangkan beberapa metrik evaluasi secara bersamaan, sehingga gambaran performa model dapat diperoleh secara lebih utuh.

Table 5. Results of LSTM parameter testing

Tabel 5. Hasil uji coba parameter LSTM

Model (neuron,epoch)	RMSE	MAE	MAPE	MSE	Keterangan
Model(50, 50)	0,1134	0,0824	83,17%	0,0128	-
Model(50, 100)	0,1113	0,0806	87,86%	0,0123	-
Model(100, 50)	0,1103	0,0791	83,87%	0,0122	Model terbaik
Model(100, 100)	0,1111	0,0802	86,30%	0,0123	-

Hasil pengujian juga menunjukkan bahwa peningkatan kompleksitas model melalui penambahan jumlah neuron maupun *epoch* tidak selalu menghasilkan perbaikan performa. Pada konfigurasi dengan *epoch* yang lebih besar, penurunan error tidak lagi signifikan dan pada beberapa kasus justru mengalami peningkatan. Kondisi ini mengindikasikan gejala *overfitting*, yaitu ketika model semakin baik dalam mempelajari pola spesifik pada data pelatihan, namun kemampuan generalisasinya terhadap data pengujian tidak meningkat secara proporsional. Hal tersebut diduga berkaitan dengan jumlah data yang relatif terbatas dibandingkan kapasitas model LSTM yang digunakan, sehingga sebagian variasi atau fluktuasi pada data pelatihan ikut dipelajari sebagai pola. Oleh karena itu, konfigurasi Model 3 (100 *neuron* dan 50 *epoch*) dipilih karena memberikan keseimbangan yang lebih baik antara kemampuan pembelajaran pola data dan kemampuan generalisasi model dibandingkan konfigurasi lainnya.

Model Terbaik antara ARCH/GARCH dan LSTM

Berdasarkan hasil perbandingan pada **Table 6**, model LSTM menunjukkan kinerja yang lebih baik dibandingkan model AR(2)-EGARCH(1,0) pada seluruh metrik evaluasi. Nilai RMSE, MAE, dan MSE yang jauh lebih rendah menunjukkan bahwa kesalahan prediksi model LSTM terhadap nilai aktual lebih kecil, sehingga model mampu merepresentasikan pola data secara lebih akurat. Penurunan nilai RMSE dari 0,7564 menjadi 0,1103 serta MAE dari 0,6303 menjadi 0,0791 mengindikasikan peningkatan kemampuan prediksi yang cukup signifikan dibandingkan model AR(2)-EGARCH(1,0).

Table 6. Best modelling results

Tabel 6. Hasil pemodelan model terbaik

Ukuran	Model AR(2)-EGARCH(1,0)	Model LSTM
RMSE	0,7564	0,1103
MAE	0,6303	0,0791
MAPE	310,21%	83,87%
MSE	0,5721	0,0122

Perbedaan yang sama juga terlihat pada nilai MAPE, dimana model LSTM menghasilkan nilai sebesar 83,87%, jauh lebih rendah dibandingkan model AR(2)-EGARCH(1,0) yang mencapai 310,21%. Meskipun metrik persentase menunjukkan tingkat kesalahan yang berbeda dibandingkan metrik berbasis skala absolut, hasil ini tetap mengindikasikan bahwa model LSTM memiliki kemampuan yang lebih baik dalam meminimalkan deviasi prediksi terhadap nilai aktual. Secara keseluruhan, konsistensi hasil pada seluruh metrik evaluasi menunjukkan bahwa model LSTM memberikan performa yang lebih unggul dalam menangkap pola deret waktu dibandingkan model AR(2)-EGARCH(1,0). Oleh karena itu, model LSTM dipilih sebagai model terbaik dan digunakan untuk proses peramalan pada periode

berikutnya. Temuan ini mengindikasikan bahwa pendekatan nonlinier berbasis deep learning pada LSTM lebih mampu menangkap kompleksitas pola data dibandingkan pendekatan volatilitas kondisional yang digunakan pada model EGARCH.

Peramalan SSTA Menggunakan Metode LSTM

Berdasarkan hasil evaluasi model, konfigurasi LSTM terbaik selanjutnya digunakan untuk melakukan peramalan SSTA di Perairan Selatan Jawa selama 60 hari setelah periode observasi terakhir, yaitu mulai 4 Desember 2025 hingga 1 Februari 2026. Hasil peramalan yang disajikan pada **Figure 4** menunjukkan adanya kecenderungan penurunan nilai SSTA sepanjang periode prediksi. Pada awal periode peramalan, nilai anomali tercatat sebesar 0,597, yang mengindikasikan kondisi suhu permukaan laut masih berada di atas rata-rata klimatologisnya. Namun, seiring berjalannya waktu, nilai anomali menunjukkan tren menurun secara bertahap hingga mencapai 0,087 pada akhir periode peramalan. Ringkasan hasil prediksi untuk seluruh periode disajikan pada **Table 7**.




Figure 4 Visualisation of LSTM forecast for next 60 days

Gambar 4 Visualisasi forecasting LSTM 60 hari ke depan

Pola penurunan tersebut mengindikasikan berkurangnya intensitas anomali suhu hangat di Perairan Selatan Jawa dan kecenderungan sistem menuju kondisi yang lebih mendekati normal. Secara kuantitatif, nilai anomali diproyeksikan turun sekitar 85% dari kondisi awal peramalan, menunjukkan adanya pelemahan sinyal pemanasan laut yang cukup signifikan. Hasil ini mengindikasikan bahwa dinamika SSTA pada periode prediksi cenderung didominasi oleh proses pendinginan relatif dibandingkan fase sebelumnya yang menunjukkan anomali positif yang lebih kuat.

Table 7. Sea surface temperature forecast for next 60 days

Tabel 7. Hasil peramalan suhu permukaan laut 60 hari kedepan

No	Tanggal	Prediksi SSTA
1	4 Desember 2025	0,597191
2	5 Desember 2025	0,554608
...
59	31 Januari 2026	0,090938
60	1 Februari 2026	0,086930

Secara oseanografis, kecenderungan penurunan anomali tersebut dapat dikaitkan dengan pengaruh variabilitas musiman yang terjadi pada periode Desember hingga Februari. Pada periode ini,

wilayah selatan Jawa memasuki musim baratan yang umumnya ditandai oleh peningkatan curah hujan, peningkatan tutupan awan, dan berkurangnya intensitas radiasi matahari yang mencapai permukaan laut. Kondisi tersebut berpotensi menurunkan akumulasi panas pada lapisan permukaan laut sehingga menyebabkan anomali suhu berangsur melemah. Dengan demikian, hasil peramalan menunjukkan bahwa potensi kejadian suhu laut yang lebih hangat dari kondisi normal diperkirakan akan berkurang pada awal tahun 2026 di wilayah penelitian.

KESIMPULAN DAN SARAN

Penelitian ini bertujuan untuk memprediksi dinamika anomali suhu permukaan laut (SSTA) di perairan selatan Jawa melalui perbandingan model ARCH-GARCH dan *Long Short-Term Memory* (LSTM). Hasil pemodelan menunjukkan bahwa AR(2)-EGARCH(1,0) merupakan model terbaik dari kelompok ARCH-GARCH berdasarkan hasil identifikasi model dan evaluasi statistik. Sementara itu, pada pendekatan LSTM, konfigurasi 100 neuron dan 50 epoch menghasilkan performa terbaik dengan nilai RMSE sebesar 0,1103, MAE sebesar 0,0791, MAPE sebesar 83,87%, dan MSE sebesar 0,0122.

Perbandingan kinerja kedua pendekatan menunjukkan bahwa model LSTM menghasilkan nilai error yang lebih rendah dibandingkan model AR(2)-EGARCH(1,0) pada seluruh metrik evaluasi, sehingga lebih baik dalam memprediksi dinamika SSTA di perairan selatan Jawa. Berdasarkan hasil tersebut, model LSTM dipilih sebagai model terbaik untuk proses peramalan. Hasil prediksi selama 60 hari setelah periode observasi terakhir menunjukkan kecenderungan penurunan nilai SSTA di wilayah penelitian. Temuan ini menunjukkan bahwa pendekatan LSTM memiliki kemampuan prediksi yang lebih baik dibandingkan model ARCH-GARCH dalam menangkap dinamika SSTA di perairan selatan Jawa, sehingga berpotensi menjadi alternatif yang lebih efektif untuk peramalan variabilitas suhu permukaan laut.

Penelitian selanjutnya dapat memperluas cakupan analisis dengan memasukkan faktor-faktor oseanografi dan iklim yang berpengaruh terhadap dinamika SSTA, seperti klorofil-a, kecepatan angin, tinggi muka laut, ENSO, dan IOD. Integrasi variabel-variabel tersebut berpotensi meningkatkan kemampuan model dalam menangkap mekanisme fisik yang mendasari perubahan suhu permukaan laut. Pengembangan model multivariat dan spasial juga perlu dipertimbangkan agar prediksi tidak hanya menggambarkan dinamika temporal SSTA, tetapi juga variasi antarwilayah yang dapat memengaruhi proses upwelling dan produktivitas perairan. Hasil penelitian ini dapat dikembangkan menjadi sistem prediksi SSTA berbasis data satelit secara *near real-time* yang terintegrasi dengan pemantauan kondisi oseanografi. Sistem tersebut berpotensi mendukung deteksi dini anomali suhu laut dan menyediakan informasi yang lebih cepat bagi pengelolaan sumber daya kelautan dan kegiatan perikanan.

DAFTAR PUSTAKA

- Akhbar, A. I., Veva Jaya, Y., & Febrianto, T. (2018). *Kajian Suhu Permukaan Laut Berdasarkan Data Citra Satelit NOAA-AVHRR dan Data Argo Float di Perairan Selatan Jawa* (Vol. 7, Issue 1). <http://ojs.umrah.ac.id/index.php/dinamikamaritim>
- Anggraeni, N. R. K., Attaqwa, R., Simangunsong, F. G. A., Gunady, S. M., Maslukah, L., & Wirasatriya, A. (2025). Analisis Spasial dan Temporal Marine Heatwave di Selat Sunda (1982-2021). *Buletin Oseanografi Marina*, 14(3), 347–361. <https://doi.org/10.14710/buloma.v14i3.68953>
- Atmadipoera, A. S., Jasmine, A. S., Purba, M., & Kuswardani, A. R. T. D. (2020). Upwelling Characteristics in the Southern Java Waters During Strong La Nina 2010 and Super El Nino 2015.

Jurnal Ilmu Dan Teknologi Kelautan Tropis, 12(1), 257–276.
<https://doi.org/10.29244/jitkt.v12i1.28977>

- Atman Maulana, H., Zefaya Sampe, M., Hanifah, F., & Matematika dan Pendidikan Matematika, J. (2017). Pemodelan dan Peramalan Deret Waktu Studi kasus: Suhu Permukaan Laut di Selatan Jawa Timur. *Math Educa Journal*, 1(2), 187–199.
- Ayuningtyas, A. D., & Muchlisoh, S. (2024). *Blue Economy Sebagai Solusi Keluar Dari Middle Income Trap*: Studi Kasus Indonesia Tahun 2001-2021. *Prosiding Seminar Nasional Official Statistics 2024*, 1108–1118.
- Bollerslev, T. (1986). *Generalized Autoregressive Conditional Heteroskedasticity*. *Journal of Econometrics*, 31(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Cheng, Y., Zhang, M., Song, Z., Wang, G., Zhao, C., Shu, Q., Zhang, Y., & Qiao, F. (2023). A quantitative analysis of marine heatwaves in response to rising sea surface temperature. *Science of the Total Environment*, 881. <https://doi.org/10.1016/j.scitotenv.2023.163396>
- Engle, R. F. (1982). *Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation*. *Econometrica*, 50(4), 987–1007. <https://doi.org/10.2307/1912773>
- Fadika, U., Rifai, A., & Rochaddi, B. (2014). *Arah Dan Kecepatan Angin Musiman Serta Kaitannya Dengan Sebaran Suhu Permukaan Laut Di Selatan Pangandaran Jawa Barat* (Vol. 3, Issue 3). <http://ejournal-s1.undip.ac.id/index.php/jose>
- Fauzan, F. D., Rayhan, D. A., Putri, H. M., & Kartiasih, F. (2024). Peramalan Konsentrasi PM2.5 Menggunakan Model ARCH/GARCH dan Long Short-Term Memory (Studi Kasus Kota Jakarta Pusat). *INFOMATEK: Jurnal Informatika, Manajemen Dan Teknologi*, 26(1), 27–44. <https://doi.org/10.23969/infomatek.v26i1.12603>
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). *Learning to Forget: Continual Prediction with LSTM*. *Neural Computation*, 12(10), 2451–2471.
- Hilal, Y. N., Nainggolan, G. D. A., Syahputri, S. H., & Kartiasih, F. (2024). Comparison of ARIMA and LSTM Methods in Predicting Jakarta Sea Level. *Jurnal Ilmu Dan Teknologi Kelautan Tropis*, 16(2), 163–178. <https://doi.org/10.29244/jitkt.v16i2.52818>
- Hobday, A. J., Alexander, L. V., Perkins, S. E., Smale, D. A., Straub, S. C., Oliver, E. C. J., Benthuisen, J. A., Burrows, M. T., Donat, M. G., Feng, M., Holbrook, N. J., Moore, P. J., Scannell, H. A., Sen Gupta, A., & Wernberg, T. (2016). A hierarchical approach to defining marine heatwaves. *Progress in Oceanography*, 141, 227–238. <https://doi.org/10.1016/j.pocean.2015.12.014>
- Hochreiter, S., & Schmidhuber, J. (1997). *Long Short-Term Memory*. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Nguyen, K. Q., & Nguyena, V. Y. (2017). Changing of Sea Surface Temperature Affects Catch of Spanish Mackerel *Scomberomorus Commerson* in the Set-Net Fishery. *Fisheries and Aquaculture Journal*, 08(04). <https://doi.org/10.4172/2150-3508.1000231>
- Ningsih, N. S., Beliyana, E., Kamila, I. H., & Tarya, A. (2025a). Long-term characteristics of marine heatwaves (1982–2021) in Indonesian water and their impact on upwelling (case study: Southern Java). *Frontiers in Marine Science*, 12. <https://doi.org/10.3389/fmars.2025.1504995>
- Oktaviani, F., Miftahuddin, & Setiawan, I. (2021). Forecasting sea surface temperature anomalies using the SARIMA ARCH/GARCH model. *Journal of Physics: Conference Series*, 1882(1). <https://doi.org/10.1088/1742-6596/1882/1/012020>
- Rahmayanti, E., Aryanie, I., Malik, I., & Adhha Haura, G. (2025). Blue Economy: Perspektif dalam Meningkatkan Nilai Ekonomi Indonesia. *Jurnal Penelitian Ekonomi Akuntansi (JENSI)*, 9, 47–60.

- Reynolds, R. W., Smith, T. M., Liu, C., Chelton, D. B., Casey, K. S., & Schlax, M. G. (2007). Daily high-resolution-blended analyses for sea surface temperature. *Journal of Climate*, 20, 5473–5496. <https://doi.org/10.1175/2007JCLI1824.1>
- Suhendi, B. A. P., Pratiwi, P., Prayoga, S. W., & Kartiasih, F. (2024). Comparison of ARIMA and Machine Learning Methods for Predicting Urban Land Surface Temperature in Jakarta. *J-COSINE (Journal of Computer Science and Informatics Engineering)*, 8(2), 89–100. <https://doi.org/10.29303/jcosine.v8i2.579>
- Song, J., Zhang, X., & Jiang, W. (2024). Sea surface temperature prediction in China Sea based on SAM-LSTM approach. *American Journal of Environmental Science and Engineering*, 8(2), 14–22. <https://doi.org/10.11648/j.ajese.20240802.11>
- Syamsuddin, M., Saitoh, S. I., Hirawake, T., Syamsudin, F., & Zainuddin, M. (2016). Interannual variation of bigeye tuna (*Thunnus obesus*) hotspots in the eastern Indian Ocean off Java. *International Journal of Remote Sensing*, 37(9), 2087–2100. <https://doi.org/10.1080/01431161.2015.1136451>
- Voyer, M. A., Schofield, C. H., Azmi, K., Warner, R. M., & Mcilgorm, A. (2018). Maritime security and the Blue Economy: intersections and interdependencies in the Indian Ocean. <https://ro.uow.edu.au/lhapapers/3358>
- Wibisana, H., Sukojo, B. M., & Lasminto, U. (2018). Penentuan Model Matematis yang Optimal Suhu Permukaan Laut di Pantai Utara Gresik Berbasis Nilai Reflektan Citra Satelit Aqua Modis. *GEOMATIKA*, 24(1), 31. <https://doi.org/10.24895/jig.2018.24-1.771>
- Zulkifli, R., Ozora, E., Ramadhan, M. A., Kacaribu, J. P., & Mahendra, R. (2023). Indonesia's Blue Economy Initiative: Oceans As The New Frontier of Economic Development. *Jurnal Perdagangan Internasional*, 1(1), 10–16. <https://doi.org/10.33197/jpi.v1i1.1083>