JURNAL PESISIR DAN LAUT TROPIS
E-ISSN: 2339-1537
Vol 14 No. 3 : 251-264 (2026)

Improving SST Prediction Accuracy of Ina-Flows Model in Karimun Jawa and Bira

(*Peningkatan Akurasi SST Ina-Flows Menggunakan Bias Correction Berbasis Machine Learning di Karimun Jawa dan Bira*)

Delfiana Yoventa Buti*, Purwanti Lelly Sabrina, Adi Mulsandi, Avrionesti

Applied Bachelor of Meteorology Study Program, College of Meteorology, Climatology, and Geophysics, Tangerang

(Received 4 Sep. 2026; Revised 19 Sep. 2026; Accepted 22 Sep. 2026)

ABSTRACT. Sea surface temperature (SST) is an important parameter in ocean-atmosphere interaction, but BMKG Ina-Flows model outputs may still contain systematic bias. This study evaluates the accuracy of Ina-Flows SST predictions and improves their performance through machine learning-based bias correction at MAWS Karimun Jawa and Bira. The dataset consists of Ina-Flows SST outputs and MAWS observations from 1 December 2023 to 7 December 2024. Data up to 30 November 2024 were used for model training and validation, while 1–7 December 2024 was used as the test period. Three algorithms were compared: Support Vector Regression (SVR), Long Short-Term Memory (LSTM), and Bidirectional Long Short-Term Memory (Bi-LSTM). Model performance was evaluated using Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Bias Error (MBE). The results show that Ina-Flows exhibits warm bias at both locations. At Karimun Jawa, LSTM produced the best performance with RMSE 0.207, MAE 0.182, and MBE -0.171, reducing RMSE by 29.83%. At Bira, Bi-LSTM performed best with RMSE 0.218, MAE 0.173, and MBE 0.011, reducing RMSE by 26.10%. These findings indicate that bias-correction effectiveness is location-dependent, so algorithm selection should be based on local validation.
Keywords: bias correction, Ina-Flows, machine learning, SST, MAWS

ABSTRAK. Suhu permukaan laut (SST) merupakan parameter penting dalam interaksi laut-atmosfer, tetapi keluaran model Ina-Flows BMKG masih dapat mengandung bias sistematis. Penelitian ini bertujuan mengevaluasi akurasi prediksi SST Ina-Flows dan meningkatkan kinerjanya melalui koreksi bias berbasis machine learning pada lokasi MAWS Karimun Jawa dan Bira. Data yang digunakan berupa keluaran SST Ina-Flows dan observasi MAWS periode 1 Desember 2023 –7 Desember 2024. Data hingga 30 November 2024 digunakan untuk pelatihan dan validasi, sedangkan periode 1–7 Desember 2024 digunakan sebagai data uji. Tiga algoritma dibandingkan, yaitu Support Vector Regression (SVR), Long Short-Term Memory (LSTM), dan Bidirectional Long Short-Term Memory (Bi-LSTM). Kinerja model dievaluasi menggunakan Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Bias Error (MBE). Hasil menunjukkan bahwa Ina-Flows mengalami warm bias pada kedua lokasi. Di Karimun Jawa, LSTM memberikan kinerja terbaik dengan RMSE 0,207, MAE 0,182, dan MBE -0,171, serta menurunkan RMSE sebesar 29,83%. Di Bira, Bi-LSTM memberikan hasil terbaik dengan RMSE 0,218, MAE 0,173, dan MBE 0,011, serta menurunkan RMSE sebesar 26,10%. Temuan ini menunjukkan bahwa efektivitas algoritma koreksi bias bergantung pada karakteristik lokasi, sehingga pemilihan metode perlu disesuaikan melalui validasi lokal.
Kata kunci: *bias correction*, Ina-Flows, *machine learning*, SST, MAWS

*corresponding author :
Email: butifiana@gmail.com

PENDAHULUAN

Suhu permukaan laut (*Sea Surface Temperature*/SST) merupakan salah satu parameter penting dalam sistem laut-atmosfer karena berperan dalam proses pertukaran energi, pembentukan cuaca maritim, dinamika iklim, serta berbagai aktivitas kelautan seperti perikanan dan keselamatan pelayaran. Variabilitas SST di wilayah tropis, termasuk perairan Indonesia, memiliki karakteristik yang kompleks akibat pengaruh interaksi monsun, arus laut, kondisi topografi perairan, serta fenomena iklim global seperti *El Niño Southern Oscillation* (ENSO) dan *Indian Ocean Dipole* (IOD). Oleh karena itu, ketersediaan prediksi SST yang akurat menjadi salah satu komponen penting dalam mendukung sistem informasi kelautan dan prakiraan kondisi laut (Wallace & Hobbs, 2006).

Model numerik oseanografi telah banyak dikembangkan untuk menghasilkan prediksi SST secara operasional. Salah satunya adalah Ina-Flows (*Indonesia Forecasting Ocean*), yaitu sistem prediksi oseanografi yang dikembangkan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) sebagai bagian dari *Ocean Forecast System* (OFS) untuk menyediakan informasi kondisi laut Indonesia. Meskipun model numerik mampu merepresentasikan dinamika laut secara fisik, keluaran model masih dapat mengalami penyimpangan terhadap kondisi observasi akibat keterbatasan resolusi spasial dan temporal, ketidakpastian kondisi awal dan batas, serta kompleksitas proses fisik laut-atmosfer yang belum sepenuhnya dapat direpresentasikan dalam model. Permasalahan bias pada model numerik SST juga masih menjadi tantangan pada berbagai sistem prediksi laut operasional di dunia (Ehret *et al*., 2012; Storto *et al*., 2025).

Berbagai penelitian menunjukkan bahwa metode *bias correction* sebagai tahap pascapemrosesan (*post-processing*) mampu meningkatkan akurasi keluaran model numerik tanpa melakukan perubahan terhadap struktur fisik model utama. Pendekatan berbasis *machine learning* mulai banyak digunakan karena mampu mempelajari hubungan nonlinier antara keluaran model dan data observasi. Fei *et al*. (2022) menerapkan model hybrid deep learning untuk mengoreksi keluaran SST HYCOM dan berhasil menurunkan RMSE secara signifikan dibandingkan LSTM dan SVR, namun tidak kalah kompetitif dari hybrid deep learning. Namun, karena kompleksitas komputasinya yang tinggi, de Mattos Neto *et al*. (2022) mengusulkan pendekatan yang lebih sederhana melalui pemodelan residual, yaitu mengoreksi sisa kesalahan dari model *machine learning* awal, dan menunjukkan peningkatan akurasi SST yang signifikan. Selanjutnya Li *et al*. (2025) memodelkan bias SST pada model TCWAGFS, dengan Bi-LSTM sebagai model terbaik yang mampu menurunkan kesalahan prediksi SST hingga mendekati 0,01 K. Sementara itu, Pasula & Subramani (2025) mengaplikasikan U-Net, Bi-LSTM dan ConvLSTM untuk *bias correction* SST keluaran GCM, mereka menemukan bahwa U-Net memberikan kinerja paling optimal dalam merepresentasikan pola SST mendekati observasi. Secara keseluruhan, penelitian-penelitian tersebut menegaskan bahwa *bias correction* berbasis *machine learning* merupakan pendekatan yang efektif, meskipun penerapannya pada model Ina-Flows dengan memanfaatkan data

observasi *in situ* di perairan Indonesia masih sangat terbatas.

Meskipun berbagai penelitian telah membuktikan efektivitas *machine learning* untuk koreksi bias SST, sebagian besar penelitian sebelumnya masih berfokus pada model global atau regional seperti HYCOM, CFSv2, GCM, maupun sistem prediksi wilayah tertentu di luar Indonesia. Kajian mengenai penerapan *bias correction* berbasis *machine learning* pada keluaran SST model Ina-Flows BMKG dengan menggunakan data observasi *in situ* di wilayah perairan Indonesia masih relatif terbatas. Selain itu, karakteristik wilayah perairan Indonesia yang memiliki kompleksitas dinamika laut berbeda antarwilayah menyebabkan performa setiap algoritma *machine learning* tidak selalu sama pada setiap lokasi.

Berdasarkan kondisi tersebut, diperlukan penelitian yang secara khusus mengevaluasi kemampuan metode *bias correction* berbasis *machine learning* dalam meningkatkan akurasi prediksi SST model Ina-Flows BMKG menggunakan data observasi langsung pada wilayah perairan Indonesia. Keunikan penelitian ini dibandingkan penelitian sebelumnya terletak pada penerapan dan perbandingan tiga algoritma *machine learning*, yaitu *Support Vector Regression* (SVR), *Long Short-Term Memory* (LSTM), dan *Bidirectional Long Short-Term Memory* (Bi-LSTM), untuk mengoreksi bias SST Ina-Flows pada dua lokasi dengan karakteristik perairan berbeda, yaitu Karimun Jawa dan Bira. Pendekatan ini diharapkan dapat memberikan informasi mengenai metode koreksi yang paling sesuai berdasarkan karakteristik lokal masing-masing wilayah.

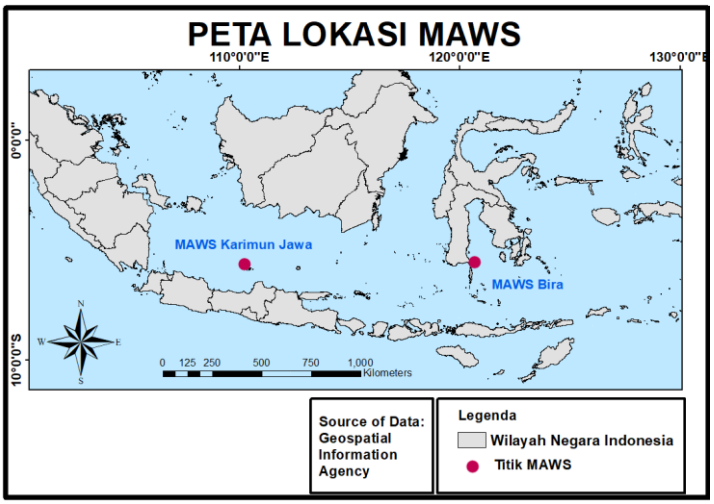
Novelty penelitian ini terletak pada penerapan dan evaluasi komparatif tiga algoritma machine learning untuk koreksi bias SST Ina-Flows menggunakan observasi in situ MAWS pada dua lokasi perairan Indonesia dengan karakteristik oseanografi berbeda.

Penelitian ini bertujuan untuk mengevaluasi akurasi prediksi suhu permukaan laut (SST) model Ina-Flows BMKG terhadap data observasi Marine Automatic Weather Station (MAWS) di Karimun Jawa dan Bira, serta menganalisis kemampuan metode *bias correction* berbasis *machine learning* menggunakan algoritma SVR, LSTM, dan Bi-LSTM dalam meningkatkan akurasi prediksi SST.

METODE PENELITIAN

Tempat dan Waktu Penelitian

Penelitian ini dilakukan pada dua lokasi pengamatan *Marine Automatic Weather Station* (MAWS), yaitu MAWS Karimun Jawa dan MAWS Bira (Gambar 1). Lokasi Karimun Jawa berada di wilayah perairan Laut Jawa, sedangkan lokasi Bira berada di wilayah pesisir Kabupaten Bulukumba, Sulawesi Selatan. Kedua lokasi tersebut dipilih karena memiliki karakteristik oseanografi yang berbeda sehingga dapat digunakan untuk mengevaluasi kemampuan metode *bias correction* berbasis *machine learning* dalam meningkatkan akurasi prediksi suhu permukaan laut (SST) model Ina-Flows BMKG.



Gambar 1. Peta lokasi penelitian

Data yang digunakan dalam penelitian ini berupa keluaran prediksi SST model Ina-Flows BMKG dan data observasi SST MAWS dengan periode 1 Desember 2023 hingga 7 Desember 2024. Data periode 1 Desember 2023 hingga 30 November 2024 digunakan sebagai data pelatihan dan validasi model. Untuk pemilihan konfigurasi model, data latih dibagi secara kronologis tanpa pengacakan menjadi 90% bagian awal sebagai data sub-training dan 10% bagian akhir sebagai data validasi. Periode 1–7 Desember 2024 digunakan sebagai data pengujian untuk mengevaluasi performa hasil koreksi bias.

Prosedur Penelitian

Jenis penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimental dan komparatif. Pendekatan kuantitatif digunakan karena analisis dilakukan pada data numerik suhu permukaan laut (SST) dan dievaluasi menggunakan metrik statistik untuk mengukur kesalahan prediksi (Kuntjojo, 2009). Pendekatan eksperimental diterapkan melalui pemberian perlakuan (treatment) berupa *bias correction* berbasis *machine learning* terhadap keluaran prediksi SST model Ina-Flows BMKG. Perubahan kinerja model dievaluasi dengan membandingkan hasil prediksi sebelum dan sesudah koreksi menggunakan metrik statistic (Hodson, 2022). Sementara itu, pendekatan komparatif digunakan untuk membandingkan kinerja tiga algoritma, yaitu *Support Vector Regression* (SVR), *Long Short-Term Memory* (LSTM), dan *Bidirectional* LSTM (Bi-LSTM), dalam meningkatkan akurasi prediksi SST di perairan Indonesia.

Penelitian ini dilakukan melalui beberapa tahapan, yaitu pengumpulan data, pengolahan data awal, penerapan metode *bias correction* berbasis *machine learning*, dan evaluasi performa model. Data SST Ina-Flows BMKG digunakan sebagai data prediktor, sedangkan data SST observasi MAWS digunakan sebagai data acuan (*ground truth*). Data observasi MAWS digunakan karena mampu merepresentasikan kondisi SST aktual pada lokasi pengamatan dan menjadi referensi dalam proses evaluasi keluaran model numerik.

Tahap awal penelitian dilakukan dengan melakukan sinkronisasi waktu antara data SST Ina-Flows dan SST

MAWS. Selanjutnya dilakukan perhitungan nilai bias antara model dan observasi menggunakan persamaan:

BiasSST = SSTobs – SSTmodel (1)

Keterangan:

BiasSST= bias suhu permukaan laut
SSTobs = SST observasi MAWS
SSTmodel = SST keluaran model Ina-Flows

Nilai bias tersebut digunakan sebagai target pembelajaran (target output) pada model *machine learning*. Konsep *bias correction* dalam penelitian ini dilakukan dengan membangun model yang mempelajari hubungan antara keluaran SST Ina-Flows dan pola kesalahan terhadap observasi MAWS. Hasil prediksi bias kemudian digunakan untuk melakukan koreksi terhadap keluaran SST Ina-Flows dengan persamaan:

SSTcorrected = SSTmodel + Biaspred (2)

Keterangan:

SSTcorrected = SST hasil koreksi bias
SSTmodel=SST keluaran model Ina-Flows
Biaspred = Bias hasil prediksi model *machine learning*

Pendekatan ini merupakan metode *post-processing* yang bertujuan mengurangi kesalahan sistematis tanpa mengubah konfigurasi fisik model Ina-Flows.

Data Ina-Flows diekstraksi pada koordinat masing-masing MAWS menggunakan pendekatan *nearest ocean grid point*. Jarak antara lokasi MAWS dan seluruh grid laut di sekitar lokasi dihitung menggunakan rumus Haversine, kemudian pencarian dibatasi pada radius sekitar 10 km. Rumus Haversine digunakan karena mampu menghitung jarak lingkaran besar (*great-circle distance*) berdasarkan koordinat lintang dan bujur pada permukaan bumi sehingga sesuai untuk analisis spasial berbasis koordinat geografis (Nabilla *et al*., 2023).

Rancangan penelitian dilakukan dengan membandingkan tiga algoritma *machine learning*, yaitu *Support Vector Regression* (SVR), *Long Short-Term Memory* (LSTM), dan *Bidirectional Long Short-Term Memory* (Bi-LSTM). Model SVR digunakan sebagai metode *machine learning* konvensional untuk mempelajari hubungan nonlinier antara SST Ina-Flows dan nilai bias. Model LSTM digunakan untuk menangkap hubungan temporal pada data deret waktu SST melalui mekanisme memori, sedangkan Bi-LSTM digunakan untuk mempelajari pola temporal dari arah maju dan mundur sehingga mampu menangkap karakteristik bias yang lebih kompleks.

Konfigurasi model ditentukan melalui proses validasi menggunakan data latih yang dibagi secara kronologis tanpa pengacakan. Sebanyak 90% bagian awal data latih digunakan sebagai *sub-training*, sedangkan 10% bagian akhir digunakan sebagai data validasi untuk memilih konfigurasi terbaik. Pemilihan konfigurasi dilakukan berdasarkan nilai RMSE validasi terendah, kemudian mempertimbangkan MAE, |MBE|, serta parameter dengan kompleksitas lebih rendah. Model SVR yang digunakan dalam penelitian ini adalah LinearSVR sebagai metode *machine learning* konvensional untuk mempelajari hubungan antara keluaran SST Ina-Flows dan nilai bias. Pemilihan LinearSVR dilakukan karena metode ini memiliki struktur yang lebih sederhana dan sesuai sebagai pembanding terhadap model *deep learning* LSTM dan Bi-LSTM. Pada model LSTM dan Bi-LSTM, pemilihan epoch dan

Tabel 1. Konfigurasi inti model *bias correction*

Komponen	SVR	LSTM	Bi-LSTM
Target prediksi	Bias SST = SSTobs - SST model	Bias SST = SSTobs - SST model	Bias SST = SSTobs - SST model
Fitur masukan	T, S, u, v, zeta + fitur waktu siklik	T, S, u, v, zeta + fitur waktu siklik	T, S, u, v, zeta + fitur waktu siklik
Bentuk input	19 fitur statistik dan waktu	Sekuens 24 × 9	Sekuens 24 × 9
Lookback	24 langkah waktu (3 hari)	24 langkah waktu (3 hari)	24 langkah waktu (3 hari)
Parameter utama	C: 0,1–20; epsilon: 0–0,20; max_iter 500.000	Hidden size 96; 2 layer; batch size 64; maksimum 300 *epoch*	hidden size 64; 1 layer *Bidirectional*; batch size 64; maksimum 300 *epoch*
Loss/optimizer	LinearSVR	Smooth L1 Loss dan AdamW	Smooth L1 Loss dan AdamW
Bias limit	0; 0,3; 0,4; 0,5; 0,75; 1,0 °C	0; 0,3; 0,4; 0,5; 0,75; 1,0 °C	0; 0,3; 0,4; 0,5; 0,75; 1,0 °C
Kriteria pemilihan	RMSE, MAE, |MBE|, C, epsilon, dan bias limit yang lebih kecil	RMSE, MAE, |MBE|, C, epsilon, dan bias limit yang lebih kecil	RMSE, MAE, |MBE|, C, epsilon, dan bias limit yang lebih kecil

bias limit dilakukan berdasarkan hasil evaluasi data validasi dengan mempertimbangkan RMSE, MAE, |MBE|, epoch lebih kecil, dan bias limit lebih kecil. Setelah konfigurasi terbaik diperoleh, model dilatih ulang menggunakan seluruh data latih sebelum diterapkan pada data uji.

Variabel input terdiri dari temperatur (T), salinitas (S), komponen arus zonal (u), komponen arus meridional (v), vortisitas relatif (zeta), serta fitur waktu siklik untuk merepresentasikan pola periodik.

Pembatasan bias (bias limit) diterapkan untuk mencegah model menghasilkan koreksi yang terlalu besar dan tidak realistis secara fisik. Fungsi hiperbolik tangent digunakan agar nilai koreksi tetap berada pada rentang yang ditentukan tanpa menimbulkan diskontinuitas pada hasil prediksi. Bias limit 0 berarti prediksi tidak dibatasi. SST terkoreksi kemudian dihitung dengan menambahkan bias hasil prediksi pada SST model Ina-Flows pada waktu target.

Evaluasi hasil koreksi dilakukan dengan membandingkan SST Ina-Flows sebelum koreksi dan SST hasil *bias correction* terhadap SST observasi MAWS. Kinerja setiap model dianalisis

menggunakan tiga parameter statistik, yaitu Root *Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Bias Error* (MBE). RMSE digunakan untuk mengukur besarnya kesalahan prediksi dengan memberikan bobot lebih besar pada kesalahan berukuran besar, sehingga sensitif terhadap deviasi ekstrem yang penting dalam aplikasi oseanografi dan meteorologi operasional (Chai dan Draxler, 2014; Hodson, 2022). MAE merepresentasikan rata-rata kesalahan absolut dan memiliki interpretasi yang langsung karena dinyatakan dalam satuan yang sama dengan variabel yang dievaluasi (Hodson, 2022). Sementara itu, MBE digunakan untuk menilai arah dan besarnya bias sistematis model. *Mean Bias Error* (MBE) digunakan untuk mengidentifikasi kecenderungan sistematis suatu model dalam menghasilkan nilai yang lebih tinggi atau lebih rendah dibandingkan observasi. Nilai MBE yang mendekati nol menunjukkan bahwa rata-rata penyimpangan model terhadap observasi semakin kecil (Wilks, 2011).

Model terbaik ditentukan berdasarkan nilai error terkecil dan kemampuan model dalam menghasilkan SST hasil koreksi yang paling mendekati data observasi MAWS pada masing-masing lokasi penelitian.

HASIL DAN PEMBAHASAN

Hasil penelitian ini menyajikan perbandingan kinerja suhu permukaan laut (SST) model Ina-Flows sebelum dan sesudah dilakukan *bias correction* menggunakan tiga algoritma *machine learning*, yaitu *Support Vector Regression* (SVR), *Long Short-Term Memory* (LSTM), dan *Bidirectional Long Short-Term Memory* (Bi-LSTM). Evaluasi dilakukan pada periode data uji 1–7 Desember 2024 menggunakan tiga metrik, *yaitu Root Mean Square Error* (RMSE*), Mean Absolute Error* (MAE), dan *Mean Bias Error* (MBE). Nilai RMSE dan MAE yang lebih kecil menunjukkan tingkat kesalahan prediksi yang lebih rendah, sedangkan nilai MBE yang semakin mendekati nol menunjukkan bahwa bias sistematis model semakin berkurang. Berdasarkan definisi MBE yang digunakan dalam penelitian ini, nilai MBE negatif menunjukkan bahwa SST model cenderung lebih tinggi daripada observasi MAWS atau mengalami *warm bias*, sedangkan nilai MBE positif menunjukkan bahwa SST model cenderung lebih rendah daripada observasi MAWS atau mengalami *cold bias*.

Hasil Evaluasi SST Ina-Flows di Lokasi MAWS Karimun Jawa

Berdasarkan Tabel 2, hasil evaluasi di Karimun Jawa menunjukkan bahwa keluaran awal Ina-Flows sebelum

Tabel 2. Perbandingan kinerja model di lokasi MAWS Karimun Jawa

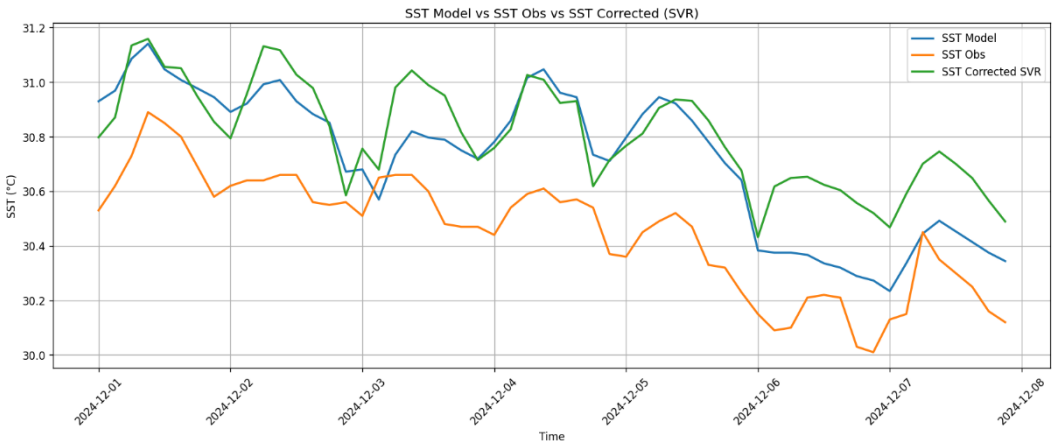
Model	RMSE	MAE	MBE
Ina-Flows (sebelum koreksi)	0,295	0,273	-0,270
Ina-Flows + SVR	0,372	0,355	-0,355
Ina-Flows + LSTM	0,207	0,182	-0,171
Ina-Flows + Bi-LSTM	0,216	0,194	-0,183

dilakukan *bias correction* memiliki nilai RMSE sebesar 0,295, MAE sebesar 0,273, dan MBE sebesar -0,270. Nilai MBE negatif menunjukkan bahwa SST model Ina-Flows cenderung lebih tinggi dibandingkan observasi MAWS, sehingga model Ina-Flows mengalami *warm bias* pada lokasi ini. Konfigurasi hasil validasi yang digunakan pada data uji ialah SVR dengan C = 0,5, epsilon = 0,20, dan bias limit 0,30°C. LSTM pada epoch 4 tanpa pembatasan bias, sedangkan Bi-LSTM pada epoch 12 dengan bias limit 0,30 °C.

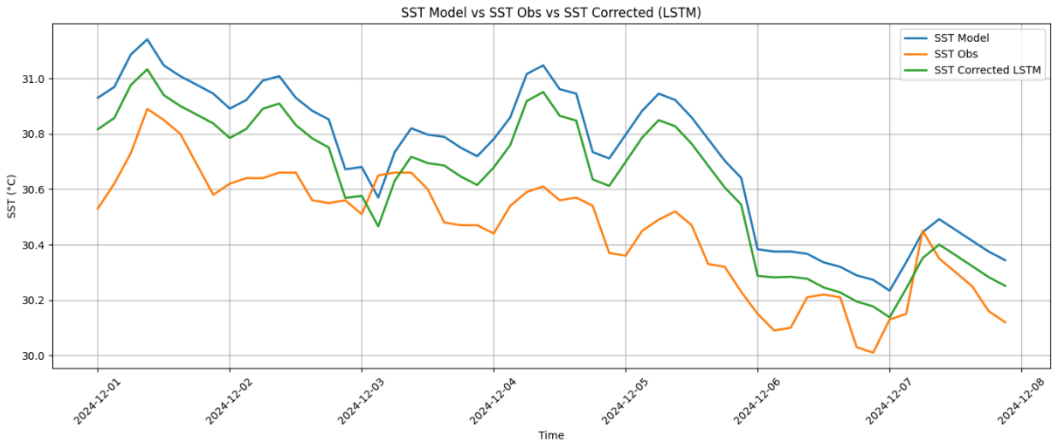
Penerapan SVR belum mampu meningkatkan akurasi prediksi SST di Karimun Jawa. Hal ini ditunjukkan oleh meningkatnya nilai RMSE menjadi 0,372, MAE menjadi 0,355, dan MBE menjadi -0,355. Dengan kata lain, kesalahan prediksi setelah koreksi menggunakan SVR justru bertambah dibandingkan kondisi awal Ina-Flows. Penurunan performa tersebut menunjukkan bahwa SVR belum mampu mempelajari pola bias SST secara optimal pada lokasi Karimun Jawa.

Sebaliknya, metode LSTM memberikan hasil terbaik di Karimun Jawa. Setelah dilakukan koreksi menggunakan LSTM, nilai RMSE menurun menjadi 0,207, MAE menjadi 0,182, dan MBE menjadi -0,171. Penurunan RMSE sebesar 29,83%, MAE sebesar 33,33%, dan |MBE| sebesar 36,67% menunjukkan bahwa LSTM mampu mengurangi kesalahan prediksi sekaligus menekan *warm bias* pada keluaran Ina-Flows. Metode Bi-LSTM juga mampu meningkatkan akurasi dengan RMSE sebesar 0,216, MAE sebesar 0,194, dan MBE sebesar -0,183, tetapi hasilnya masih sedikit lebih rendah dibandingkan LSTM. Dengan demikian, LSTM merupakan metode *bias correction* yang paling efektif untuk lokasi Karimun Jawa.

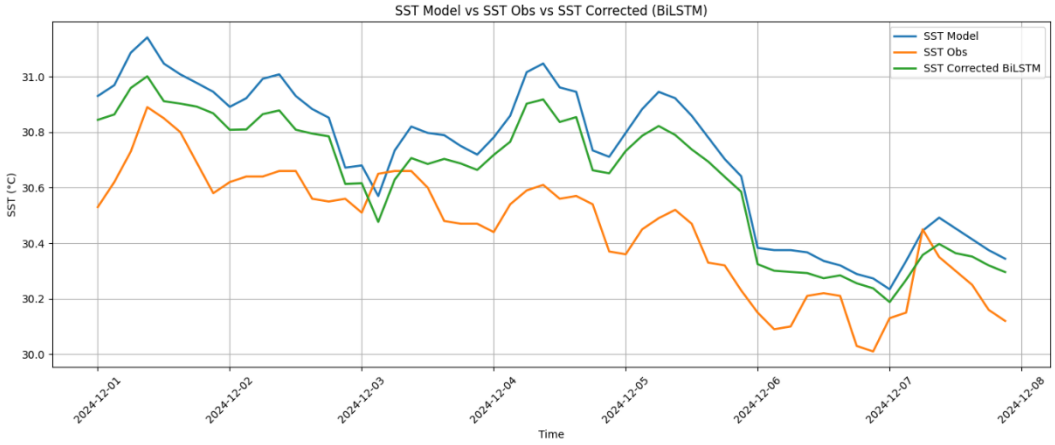
Secara visual, grafik perbandingan SST model, SST observasi, dan SST terkoreksi menunjukkan bahwa hasil koreksi LSTM lebih mendekati pola observasi MAWS dibandingkan SVR dan Bi-LSTM. Hasil SVR masih cenderung mempertahankan *warm bias*, sedangkan LSTM mampu mengikuti variasi SST observasi dengan kesalahan yang lebih kecil. Bi-LSTM juga menunjukkan perbaikan, tetapi selisihnya terhadap observasi masih lebih besar dibandingkan LSTM.



Gambar 2. Grafik perbandingan SST model, SST observasi, dan SST hasil *bias correction* menggunakan SVR di MAWS Karimun Jawa



Gambar 3. Grafik perbandingan SST model, SST observasi, dan SST hasil *bias correction* menggunakan LSTM di MAWS Karimun Jawa



Gambar 4. Grafik perbandingan SST model, SST observasi, dan SST hasil *bias correction* menggunakan Bi-LSTM di MAWS Karimun Jawa

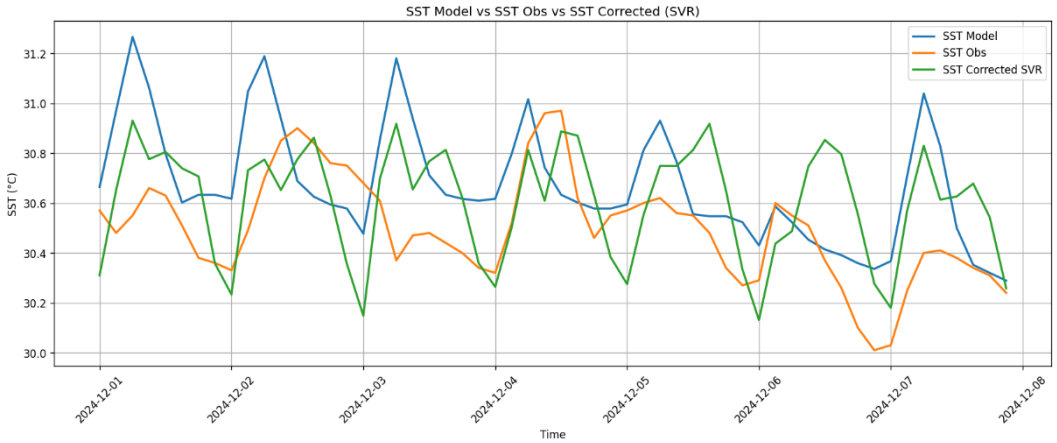
Hasil Evaluasi SST Ina-Flows di Lokasi MAWS Bira

Hasil evaluasi di Bira pada Tabel 3 menunjukkan bahwa Ina-Flows sebelum koreksi memiliki RMSE sebesar 0,295, MAE sebesar 0,234, dan MBE sebesar -0,175. Nilai MBE negatif menunjukkan bahwa SST model Ina-Flows di Bira juga cenderung lebih tinggi daripada SST observasi MAWS, meskipun besar biasnya lebih kecil dibandingkan Karimun Jawa. Konfigurasi hasil validasi yang diterapkan ialah SVR dengan C = 0,5, epsilon = 0,20, dan bias limit 0,75 °C. LSTM pada epoch 32 tanpa pembatasan bias sedangkan Bi-LSTM pada epoch 7 dengan bias limit 0,40 °C.

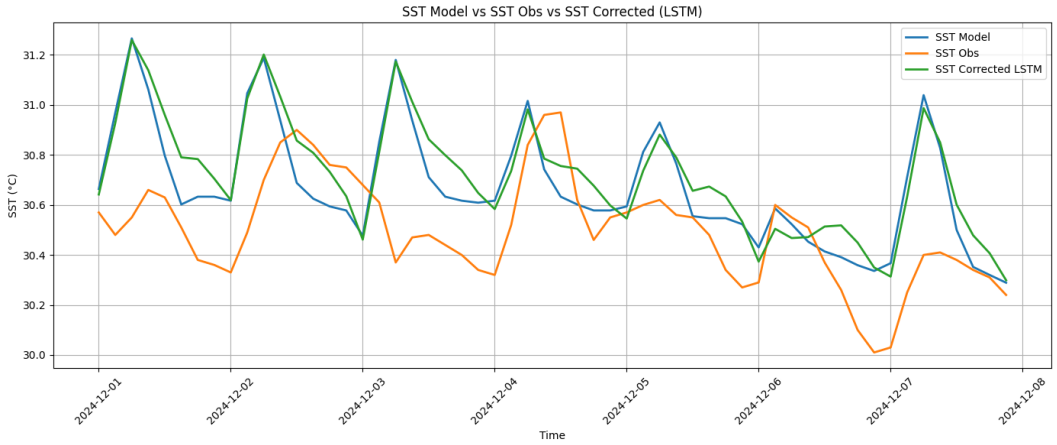
Penerapan SVR mampu memberikan peningkatan akurasi, tetapi peningkatannya relatif kecil. Nilai RMSE menurun menjadi 0,263, MAE menjadi 0,221, dan MBE menjadi -0,107. Penurunan RMSE sebesar 10,85%, MAE sebesar 5,56%, dan |MBE| sebesar 38,86% menunjukkan bahwa SVR mampu mengurangi bias sistematis, tetapi belum memberikan penurunan kesalahan yang besar.

Tabel 3. Perbandingan kinerja model di lokasi MAWS Bira

Model	RMSE	MAE	MBE
Ina-Flows (sebelum koreksi)	0,295	0,234	-0,175
Ina-Flows + SVR	0,263	0,221	-0,107
Ina-Flows + LSTM	0,311	0,258	-0,220
Ina-Flows + Bi-LSTM	0,218	0,173	0,011

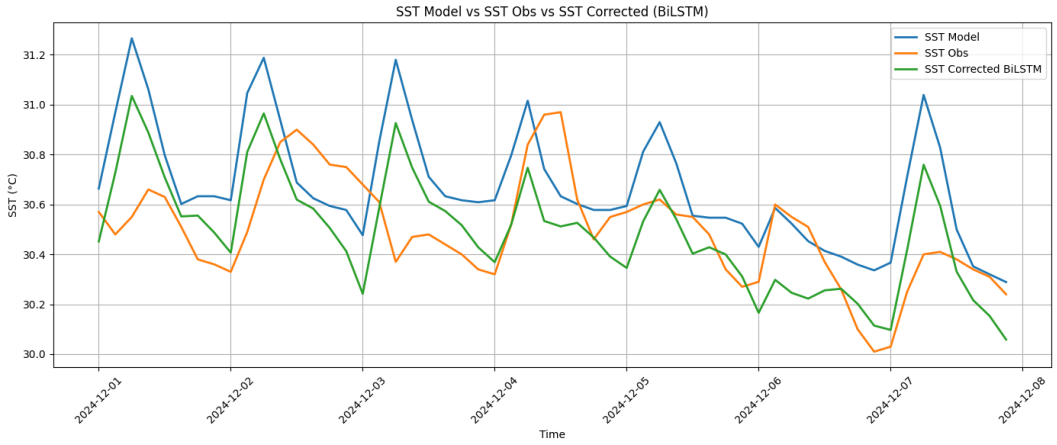


Gambar 5. Grafik perbandingan SST model, SST observasi, dan SST hasil *bias correction* menggunakan SVR di MAWS Bira



Gambar 6. Grafik perbandingan SST model, SST observasi, dan SST hasil *bias correction* menggunakan LSTM di MAWS Bira

Berbeda dengan SVR, penerapan LSTM di Bira justru menurunkan performa model Ina-Flows. Nilai RMSE meningkat menjadi 0,311, MAE menjadi 0,258, dan MBE menjadi -0,220. Nilai tersebut menunjukkan bahwa LSTM belum mampu menghasilkan koreksi yang sesuai pada lokasi Bira. Hal ini dapat disebabkan oleh pola kesalahan pada periode uji yang



Gambar 7. Grafik perbandingan SST model, SST observasi, dan SST hasil *bias correction* menggunakan Bi-LSTM di MAWS Bira

kurang sesuai dengan pola yang dipelajari model selama periode pelatihan.

Metode Bi-LSTM memberikan hasil terbaik di Bira. Nilai RMSE menurun menjadi 0,218, MAE menjadi 0,173, dan MBE menjadi 0,011. Penurunan RMSE sebesar 26,10%, MAE sebesar 26,07%, dan |MBE| sebesar 93,71% menunjukkan bahwa Bi-LSTM mampu mengurangi kesalahan prediksi sekaligus menekan bias sistematis hingga sangat kecil. Nilai MBE yang mendekati nol menunjukkan bahwa hasil koreksi Bi-LSTM hampir tidak memiliki bias rata-rata terhadap observasi MAWS. Dengan demikian, Bi-LSTM merupakan metode terbaik untuk lokasi Bira.

Secara visual, hasil koreksi Bi-LSTM menunjukkan pola yang paling mendekati observasi MAWS dibandingkan metode lainnya. SVR memperbaiki sebagian bias, tetapi masih belum optimal dalam mengikuti variasi SST observasi. Sementara itu, LSTM cenderung memperbesar selisih terhadap observasi, sehingga tidak menjadi metode yang sesuai untuk lokasi Bira.

Hasil penelitian menunjukkan bahwa kemampuan koreksi bias SST Ina-Flows bersifat spesifik terhadap lokasi. Sebelum koreksi, kedua lokasi sama-sama menunjukkan *warm bias*, tetapi besar bias dan respons terhadap algoritma berbeda. Di Karimun Jawa, LSTM memberikan penurunan RMSE dari 0,295 menjadi 0,207 atau sebesar 29,83%, sedangkan di Bira Bi-LSTM memberikan penurunan RMSE dari 0,295 menjadi 0,218 atau sebesar 26,10%. Perbedaan tersebut menunjukkan bahwa satu algoritma tidak selalu memberikan performa yang sama pada karakteristik deret waktu dan pola kesalahan yang berbeda. Hal ini sejalan dengan (Storto *et al*., 2025), yang menunjukkan bahwa bias SST pada model oseanografi dapat bersifat *state-dependent* dan dipengaruhi oleh kondisi atmosfer, keadaan laut, serta proses fisik seperti fluks panas, pencampuran vertikal, dan penetrasi radiasi. Dong *et al*. (2025) juga menunjukkan bahwa pendekatan *deep learning* dapat meningkatkan koreksi SST karena kemampuannya mempelajari evolusi bias yang bersifat nonlinier. Dengan demikian, perbedaan performa algoritma antara Karimun Jawa dan Bira dapat dipahami sebagai respons model terhadap struktur bias dan karakteristik

temporal yang berbeda pada masing-masing lokasi, bukan sebagai indikasi bahwa satu metode secara universal lebih baik.

Performa LSTM yang paling baik di Karimun Jawa dapat dikaitkan dengan kemampuan arsitektur ini dalam mempertahankan informasi historis melalui mekanisme *memory cell* sehingga hubungan temporal jangka pendek maupun jangka panjang pada deret waktu dapat dipelajari secara lebih efektif. Dalam penelitian ini, LSTM menurunkan RMSE, MAE, dan |MBE| masing-masing sebesar 29,83%, 33,33%, dan 36,67%. Hal tersebut mengindikasikan bahwa informasi yang terdapat pada jendela masukan 24 langkah waktu telah cukup untuk mempelajari pola kesalahan Ina-Flows di Karimun Jawa tanpa membutuhkan kompleksitas tambahan dari pemrosesan *bidirectional*. de Mattos Neto *et al*. (2022) menjelaskan bahwa kemampuan LSTM dalam menangkap dependensi temporal jangka panjang membuatnya sesuai untuk pemodelan SST dan menunjukkan bahwa keberhasilan model juga bergantung pada karakteristik deret waktu yang dianalisis. Hasil tersebut juga konsisten dengan Choi *et al*. (2023), yang menunjukkan bahwa model berbasis LSTM mampu digunakan untuk prediksi SST karena dapat mempelajari pola temporal dari data deret waktu laut. Hal ini memperkuat bahwa efektivitas LSTM tidak hanya ditentukan oleh arsitektur model, tetapi juga oleh kesesuaian antara struktur temporal data dan karakteristik wilayah kajian. Oleh karena itu, keunggulan LSTM di Karimun Jawa kemungkinan berkaitan dengan kesesuaian antara struktur temporal bias pada lokasi tersebut dan kemampuan LSTM dalam mempertahankan informasi historis yang relevan.

Hasil yang berbeda diperoleh di Bira, di mana Bi-LSTM memberikan performa terbaik dengan RMSE 0,218, MAE 0,173, dan MBE 0,011. Nilai MBE yang sangat dekat dengan nol menunjukkan bahwa selain menurunkan besar kesalahan, Bi-LSTM juga mampu mengurangi bias sistematis Ina-Flows secara substansial. Bi-LSTM memproses urutan masukan melalui dua arah dalam jendela data yang tersedia, sehingga representasi temporal dapat dibangun dari urutan maju dan mundur. Mekanisme tersebut dapat memberikan informasi konteks temporal yang lebih lengkap ketika pola deret waktu atau residual lebih kompleks dibandingkan yang dapat direpresentasikan secara optimal oleh LSTM satu arah. Zrira *et al*. (2024), pada penelitian prediksi SST di empat wilayah laut Maroko, juga menunjukkan bahwa Bi-LSTM mampu menangkap dependensi temporal melalui pemrosesan maju dan mundur dan memberikan hasil yang lebih baik dibandingkan beberapa model pembanding, termasuk LSTM dan SVR. Dengan demikian, keunggulan Bi-LSTM di Bira dalam penelitian ini konsisten dengan kemampuan arsitektur bidirectional untuk merepresentasikan dependensi temporal SST yang lebih kompleks.

Perbedaan hasil LSTM pada kedua lokasi juga memperlihatkan pentingnya kesesuaian antara kompleksitas model dengan struktur data. Di Karimun Jawa, LSTM memberikan hasil terbaik, sedangkan di Bira penggunaan LSTM justru meningkatkan RMSE dari 0,295 menjadi 0,311. Kondisi tersebut tidak berarti bahwa LSTM secara umum tidak sesuai untuk Bira, tetapi menunjukkan bahwa pola yang dipelajari selama pelatihan belum dapat digeneralisasikan sebaik Bi-LSTM pada periode pengujian.

de Mattos Neto *et al*. (2022) menekankan bahwa performa metode *machine learning* pada SST dapat dipengaruhi oleh model *misspecification, overfitting, underfitting*, pemilihan parameter, serta karakteristik deret waktu; bahkan model yang sama dapat menghasilkan performa berbeda pada seri SST dari lokasi yang berbeda. Hasil tersebut mendukung temuan penelitian ini bahwa pemilihan metode koreksi bias perlu dilakukan berdasarkan validasi pada masing-masing lokasi, bukan menggunakan satu algoritma secara seragam untuk seluruh wilayah.

Secara operasional, penurunan RMSE sebesar 29,83% di Karimun Jawa dan 26,10% di Bira menunjukkan bahwa *machine-learning-based bias correction* berpotensi digunakan sebagai tahap *post-processing* untuk mendekatkan prediksi SST Ina-Flows terhadap observasi tanpa mengubah struktur utama model numerik. Namun, perbedaan algoritma terbaik pada kedua lokasi menunjukkan bahwa implementasi operasional sebaiknya mempertimbangkan kalibrasi dan validasi secara lokal. Temuan ini sejalan dengan hasil penelitian *bias correction* SST sebelumnya yang menunjukkan bahwa metode *deep learning* dapat memberikan peningkatan akurasi yang berarti, tetapi efektivitas koreksi tetap dipengaruhi karakteristik data, konfigurasi model, dan wilayah penerapannya.

KESIMPULAN

Bias correction berbasis *machine learning* mampu meningkatkan akurasi prediksi SST model Ina-Flows pada lokasi Karimun Jawa dan Bira. LSTM menjadi metode terbaik di Karimun Jawa dengan penurunan RMSE sebesar 29,83%, sedangkan Bi-LSTM menjadi metode terbaik di Bira dengan penurunan RMSE sebesar 26,10%. Tidak ada satu algoritma yang unggul untuk semua lokasi, sehingga pemilihan algoritma perlu mempertimbangkan karakteristik masing-masing wilayah penelitian.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Sekolah Tinggi Meteorologi Klimatologi dan Geofisika serta Pusat Meteorologi Maritim BMKG atas dukungan data dan fasilitas yang digunakan dalam penelitian ini.

DAFTAR PUSTAKA

Chai, T., Draxler, R. R. 2014. Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? Arguments Against Avoiding Rmse in The Literature. *Geoscientific Model Development*, 7(3), 1247–1250. https://doi.org/10.5194/gmd-7-1247-2014.

Choi, H.-M., Kim, M.-K., Yang, H. 2023. Deep-learning Model for Sea Surface Temperature Prediction Near The Korean Peninsula. *Deep Sea Research Part II: Topical Studies in Oceanography*, 208, 105262. https://doi.org/10.1016/j.dsr2.2023.105262

de Mattos Neto, P. S. G., Cavalcanti, G. D. C., Santos Júnior, D. S. de O., Silva, E. G. 2022. Hybrid Systems Using Residual Modeling for Sea Surface Temperature Forecasting. *Scientific Reports*, 12(1), 487. https://doi.org/10.1038/s41598-021-04238-z.

Dong, W., Han, G., Li, W., Wu, H., Zheng, Q., Wu, X., Zhang, M., Cao, L., Ji, Z. 2025. A Comparative Evaluation of Two Bias Correction Approaches for Sst Forecasting: Data Assimilation Versus Deep Learning Strategies. *Remote Sensing*, 17(9), 1602. https://doi.org/10.3390/rs17091602.

Ehret, U., Zehe, E., Wulfmeyer, V., Warrach-Sagi, K., Liebert, J. 2012. Should We Apply Bias Correction to Global and Regional Climate Model Data? *Hydrology and Earth System Sciences*, 16(9), 3391–3404. https://doi.org/10.5194/hess-16-3391-2012.

Fei, T., Huang, B., Wang, X., Zhu, J., Chen, Y., Wang, H., Zhang, W. 2022. A Hybrid Deep Learning Model for The Bias Correction of Sst Numerical Forecast Products Using Satellite Data. *Remote Sensing*, 14(6), 1339. https://doi.org/10.3390/rs14061339.

Hodson, T. O. 2022. Root-Mean-Square Error (RMSE) or Mean Absolute Error (MAE): When to Use Them or Not. *Geoscientific Model Development*, 15(14), 5481–5487. https://doi.org/10.5194/gmd-15-5481-2022.

Kuntjojo. 2009. Metodologi Penelitian. Universitas Nusantara PGRI Kediri. 56 hal.

Li, K. S.-M., Sinhabahu, N., Tsuang, B.-J., Wu, F.-C., Tseng, W.-L., Kuo, P.-H., Wang, S.-J., Liu, P.-Y., Chen, J.-H., Wang, B.-M., Lan, Y.-Y., Kung, S.-Y. 2025. Enhancing Extended Weather Forecasts in The TCWAGFS Model Using Deep Learning Method for SST Bias Correction. *EGUsphere*. https://doi.org/10.5194/egusphere-2025-142.

Nabilla, V. H., Fitria, D., Permana, D., Fitri, F. 2023. Comparison of Haversine and Euclidean Distance Formulas for Calculating Distance Between Regencies in West Sumatra. *UNP Journal of Statistics and Data Science*, 1(3), 120–125. https://doi.org/10.24036/ujsds/vol1-iss3/39.

Pasula, A., Subramani, D. N. 2025. Global Climate Model Bias Correction Using Deep Learning. *Machine Learning: Earth*, 1(1), 015001. https://doi.org/10.1088/3049-4753/ade9c3.

Storto, A., Frolov, S., Slivinski, L., Yang, C. 2025. Correction of Sea Surface Biases in The Nemo Ocean General Circulation Model Using Neural Networks. *Geoscientific Model Development*, 18, 4789–4804. https://doi.org/10.5194/gmd-18-4789-2025.

Wallace, J. M., Hobbs, P. V. 2006. Atmospheric Science: An Introductory Survey. Elsevier. p 504.

Wilks, D. S. 2011. Statistical Methods in the Atmospheric Sciences. Academic Press. p 676.

Zrira, N., Kamal-Idrissi, A., Farssi, R., Khan, H. A. 2024. Time Series Prediction of Sea Surface Temperature Based on BiLSTM Model with Attention Mechanism. *Journal of Sea Research*, 198, 102472. https://doi.org/10.1016/j.seares.2024.102472.