

**PENERAPAN *FEATURE SELECTION* DALAM MEMPREDIKSI TINGGI
GELOMBANG LAUT SIGNIFIKAN**

Application of feature selection in predicting significant sea wave heights

**Willdan Aprizal Arifin^{1*}, Luthfi Anzani¹, Ma'ruf¹, Anton Daud², Lukman Handyanto¹,
Raisa Maulidia¹, Ramzan Pradana Maulsyid¹**

¹Universitas Pendidikan Indonesia, Jl. Dr. Setiabudi No.229, Isola, Kec. Sukasari, Kota
Bandung, Jawa Barat 40154

²Badan Meteorologi Klimatologi dan Geofisika Kota Serang, Jl. Raya Taktakan No.27, Kec.
Taktakan, Kota Serang, Banten 42162

*Corresponding author, e-mail: willdanarifin@upi.edu

ABSTRACT

Significant wave height (Hs) is a key indicator for monitoring sea-state variability and supporting maritime safety operations. This study develops a prediction model for Hs using a Long Short-Term Memory (LSTM) network combined with Spearman-based feature selection. This analysis was not merely intended to measure association, but explicitly served as the feature selection procedure to determine the most relevant predictors for the LSTM model. The dataset was obtained from the BMKG Automatic Weather Station (AWS) for the period 2022–2025 and includes multiple meteorological and oceanographic variables. Feature selection identified wind speed, sea surface temperature, water level, relative humidity, and wind direction as the most influential predictors of Hs. These variables were used as inputs in the multivariate LSTM model. Model performance was assessed using Mean Squared Error (MSE), Mean Absolute Error (MAE), and the coefficient of determination (R²). The results show an MSE of 0.00076, MAE of 0.0179, and an R² of 0.9666, indicating that the model is capable of capturing the temporal dynamics of Hs with high accuracy. The integration of Spearman feature selection and LSTM demonstrates strong potential for operational wave forecasting and supports coastal monitoring efforts in Indonesia.

Keywords: *AWS, LSTM, Prediction, Significant wave, Spearman*

ABSTRAK

Tinggi gelombang signifikan (Hs) merupakan indikator utama dalam memantau kondisi laut dan keselamatan aktivitas kelautan. Penelitian ini bertujuan mengembangkan model prediksi Hs menggunakan algoritma *Long Short-Term Memory* (LSTM) dengan pendekatan seleksi fitur berbasis korelasi Spearman. Analisis ini tidak hanya digunakan untuk melihat hubungan antarvariabel, tetapi juga secara eksplisit berfungsi sebagai langkah seleksi fitur untuk menentukan prediktor paling relevan bagi model LSTM. Data diperoleh dari *Automatic Weather Station* (AWS) milik BMKG untuk periode 2022–2025 yang mencakup berbagai parameter meteorologi dan oseanografi. Seleksi fitur dilakukan untuk mengidentifikasi variabel paling berpengaruh terhadap Hs. Hasil analisis menunjukkan kecepatan angin memiliki korelasi tertinggi (0,98), diikuti oleh suhu air laut, tinggi muka air, kelembaban relatif, dan arah angin. Variabel terpilih digunakan sebagai input pada model LSTM multivariat. Evaluasi model menggunakan *Mean Squared Error* (MSE), *Mean Absolute Error*

(MAE), dan koefisien determinasi (R^2). Hasil menunjukkan MSE sebesar 0,00076, MAE sebesar 0,0179, dan R^2 sebesar 0,9666. Nilai ini menunjukkan bahwa model memiliki akurasi tinggi dan mampu merepresentasikan pola fluktuasi Hs secara baik. Temuan ini menunjukkan bahwa integrasi seleksi fitur *Spearman* dan LSTM efektif untuk prediksi tinggi gelombang, serta berpotensi diterapkan dalam sistem pemantauan gelombang di wilayah pesisir Indonesia.

Kata kunci: AWS, Gelombang signifikan, LSTM, Prediksi, *Spearman*

PENDAHULUAN

Gelombang laut merupakan fenomena yang kompleks, yang berasal dari berbagai arah berbeda serta memiliki amplitudo dan periode yang bervariasi (Ouyang *et al.*, 2024). Namun, tingginya variasi dalam karakteristik gelombang menyebabkan representasi tunggal tidak cukup untuk mencerminkan fenomena gelombang laut (Mudho & Pranowo, 2024). Oleh karena itu, tinggi gelombang signifikan digunakan sebagai parameter utama yang dapat merepresentasikan karakteristik umum dari kondisi gelombang laut (James & Panchang, 2022). Hal ini dikarenakan gelombang signifikan memiliki peran krusial dalam berbagai aspek kelautan, termasuk keselamatan pelayaran, perencanaan zona pesisir, dan kegiatan perikanan.

Prediksi tinggi gelombang yang akurat memerlukan data yang terekam secara kontinu dan real-time. Badan Meteorologi, Klimatologi dan Geofisika (BMKG) sebagai lembaga resmi pengamat cuaca dan gelombang di Indonesia, telah menyediakan *Automatic Weather Station* (AWS) yang berfungsi untuk mengumpulkan dan merekam parameter cuaca secara otomatis (Suandewi *et al.*, 2023). Sistem AWS mampu merekam data meteorologi seperti suhu, kelembapan, tekanan udara, arah dan kecepatan angin, serta curah hujan secara kontinu dalam interval waktu tertentu (Husen *et al.*, 2025). Kemampuan AWS dalam menyediakan data cuaca secara real-time menjadikannya sumber informasi penting dalam berbagai sektor, termasuk kelautan (Millianda, 2025).


Pemanfaatan data AWS untuk memprediksi tinggi gelombang tidak lepas dari sejumlah tantangan. Tidak semua parameter yang direkam memiliki hubungan langsung dengan tinggi gelombang. Amiruddin dan Ishak (2022) menyatakan bahwa keberadaan fitur yang tidak relevan dapat menyebabkan model menangkap informasi yang tidak esensial, sehingga meningkatkan risiko *overfitting* dan menurunkan tingkat akurasi. Oleh karena itu diperlukan mekanisme seleksi fitur untuk mengidentifikasi parameter yang paling berpengaruh. *Feature selection* merupakan metode statistik dan komputasional yang bertujuan menyaring sekumpulan fitur yang memberikan kontribusi terbesar terhadap variabel target.

Dengan pendekatan ini, model prediksi dapat disusun secara lebih efisien, akurat, serta mudah untuk ditafsirkan.

Penelitian ini menggunakan metode korelasi *Spearman* sebagai pendekatan *feature selection* untuk memilih parameter meteorologi yang paling berpengaruh terhadap tinggi gelombang signifikan. *Spearman* dipilih karena data laut, khususnya parameter-parameter meteorologi seperti kecepatan angin, tekanan udara, dan suhu, cenderung bersifat fluktuatif. Korelasi *Spearman* merupakan metode statistik non-parametrik yang digunakan untuk menilai kekuatan dan arah hubungan monotonik antara dua variabel (Akma, 2023), sehingga mampu menangkap keterkaitan meskipun hubungan antar variabel tidak bersifat linier. Dengan menggunakan pendekatan ini, parameter-parameter yang menunjukkan korelasi rendah atau tidak signifikan terhadap tinggi gelombang dapat dieliminasi, sehingga model hanya dibangun berdasarkan fitur-fitur yang relevan.

Penelitian ini bertujuan untuk menerapkan metode *feature selection* terhadap data AWS guna menghasilkan model prediksi tinggi gelombang signifikan yang lebih optimal. Dengan mengeliminasi fitur-fitur yang tidak relevan, diharapkan model yang dibangun dapat memberikan hasil yang lebih andal serta responsif terhadap perubahan kondisi cuaca. Selain meningkatkan akurasi prediksi, pendekatan ini juga mendukung pemanfaatan data AWS secara lebih efektif dalam sistem peringatan dini dan pengelolaan risiko kelautan. Hasil dari penelitian ini diharapkan dapat menjadi dasar pengembangan sistem prediksi gelombang yang adaptif dan dapat diimplementasikan secara luas di wilayah pesisir Indonesia.

METODE PENELITIAN



Gambar 2.1. Diagram alur penelitian

Tahapan yang dilakukan dalam penelitian ini terdiri dari 5 tahapan yang meliputi pengumpulan data, *preprocessing* data, *feature selection*, pembangunan model, dan yang terakhir evaluasi. Diagram dari tahapan penelitian disajikan pada Gambar 2.1.

2.1. Pengumpulan Data

Penelitian ini menggunakan data dari alat AWS milik BMKG, yang merekam berbagai parameter cuaca dan laut. Parameter tersebut mencakup kecepatan dan arah angin, suhu udara, tekanan udara, kelembaban relatif, curah hujan, radiasi matahari, serta temperatur permukaan laut. Data dikumpulkan dalam rentang waktu 2022 hingga 2025 dengan resolusi temporal per menit. Selain itu, data tinggi gelombang signifikan digunakan sebagai variabel target pada pemodelan. Nilai H_s tidak didapatkan secara langsung dari AWS, melainkan diperoleh melalui perhitungan berdasarkan parameter angin yang tersedia.

2.2. Pre-processing Data

Tahap *pre-processing data* dalam penelitian ini dilakukan untuk mempersiapkan data sebelum memasuki proses seleksi fitur dan pemodelan. Pada dasarnya, tahapan *pre-processing* dilakukan untuk meningkatkan kualitas data dengan cara merapikan, menyusun ulang, dan mempersiapkan data agar dapat diolah secara optimal oleh model

machine learning, tanpa menghilangkan atau mengubah substansi informasi yang ada di dalamnya (Inayah *et al.*, 2022; Putra *et al.*, 2024).

Tahap ini mencakup beberapa proses yang pertama, data AWS berasal dari tiga stasiun, yaitu Merak, Ciwandan, dan Bakauheni. Selanjutnya metode *delaunay triangulation* digunakan untuk membuat pola spasial yang lebih representatif, dengan membuat 50 titik sampel menggunakan metode *random point sampling* di dalam area segitiga yang dibentuk oleh ketiga stasiun. Parameter angin dari tiga stasiun AWS diinterpolasi ke 50 titik menggunakan interpolator linear multivariat (LinearNDInterpolator). Parameter yang diinterpolasi meliputi kecepatan angin dan arah angin. Nilai hasil interpolasi digunakan sebagai input perhitungan *fetch* dan Hs pada masing-masing titik. *Fetch* dihitung pada delapan arah mata angin dengan mempertimbangkan deviasi sudut $\pm 6^\circ$ sampai $\pm 42^\circ$. Jarak *fetch* merupakan panjang lintasan angin bebas hambatan dari titik pengamatan menuju batas daratan terdekat (Arifin *et al.*, 2025). Berikut ini persamaan yang digunakan untuk menentukan *fetch* efektif rata-rata (Arafat, 2021):

$$f_{eff} = \frac{\sum X_i \cos \alpha}{\sum \cos \alpha}$$

dengan X_i sebagai panjang segmen *fetch* dan α sebagai deviasi sudut dari arah angin utama. Kemudian nilai Hs diestimasi dengan model *Sverdrup Munk Bretschneider* (SMB) untuk kondisi *fetch* terbatas.

$$H = 0.283 \tanh [0.0125 F^{0.42}]$$

Perhitungan dilakukan untuk setiap timestamp berdasarkan nilai kecepatan angin terinterpolasi pada masing-masing titik. Nilai Hs yang dihasilkan digunakan sebagai variabel target pada pemodelan LSTM. Selain itu, *pre-processing* data difokuskan pada penghapusan data yang tidak lengkap serta penggabungan data dari berbagai sumber. Penghapusan dilakukan terhadap entri-entri yang memiliki nilai kosong (*missing values*) pada salah satu atau beberapa parameter, baik pada data AWS maupun data Hs. Proses ini bertujuan untuk menjaga integritas dan kualitas data yang digunakan dalam analisis.

Setelah proses pembersihan selesai, seluruh parameter cuaca dari AWS digabungkan dengan data Hs berdasarkan kesesuaian waktu pencatatan (*timestamp*), sehingga diperoleh satu kesatuan dataset yang memuat variabel input dan target secara terstruktur. Dataset hasil *pre-processing* ini selanjutnya digunakan pada tahap seleksi fitur

untuk menentukan variabel-variabel yang paling relevan dalam memprediksi tinggi gelombang signifikan.

2.3. Feature selection

Uji korelasi *Spearman* adalah metode korelasi yang dikemukakan oleh Carl Spearman pada tahun 1904 (Pamungkasih, 2023). Salah satu keunggulan metode *Spearman* adalah fleksibilitasnya dalam menganalisis data yang tidak berdistribusi normal maupun berskala ordinal (Putra *et al.*, 2025). Dalam penelitian ini, korelasi *Spearman* digunakan untuk mengevaluasi keterkaitan antara masing-masing parameter meteorologi dari AWS (kecepatan angin, suhu, tekanan udara, dll) dengan Hs sebagai variabel target. Fitur-fitur yang memiliki nilai korelasi rendah atau tidak signifikan terhadap Hs akan dieliminasi, sedangkan fitur-fitur dengan korelasi yang cukup kuat akan dipertahankan untuk proses pemodelan. Tahapan ini bertujuan untuk meningkatkan efisiensi, mengurangi kompleksitas model, dan memperoleh hasil prediksi yang lebih akurat. Adapun rumus koefisien korelasi *spearman* yang digunakan adalah sebagai berikut (Nurhalijah *et al.*, 2024):

$$\sigma = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2-1)}$$

Keterangan:

σ = Nilai korelasi *spearman*

d = Selisih antara X dan Y

n = Jumlah pasangan (data)

Dalam proses seleksi fitur, interpretasi nilai koefisien korelasi *Spearman* dilakukan berdasarkan klasifikasi tingkat kekuatan hubungan antar variabel. Tabel 2.1 menyajikan kategori untuk menilai kuat dan lemahnya korelasi (Anandari, 2022; Mustofani & Hariyani, 2023; Pramungkasih, 2023).

Tabel 2.1. Kriteria tingkat kekuatan korelasi.

| Nilai koefisien korelasi | Kriteria korelasi |
|--------------------------|-------------------|
| 0,00 - 0,25 | Sangat lemah |
| 0,26 - 0,50 | Cukup |

| | |
|-------------|-------------|
| 0,51 - 0,75 | Kuat |
| 0,76 - 0,99 | Sangat Kuat |
| 1,00 | Sempurna |

2.4. Pembangunan Model

Long Short-Term Memory (LSTM) merupakan pengembangan dari arsitektur *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi keterbatasan RNN dalam mempertahankan informasi jangka panjang. RNN cenderung kesulitan dalam memproses data yang bergantung pada konteks atau informasi yang tersimpan dalam rentang waktu yang cukup lama, sehingga LSTM hadir sebagai solusi untuk memperbaiki kelemahan tersebut (Milniadi dan Adiwijaya, 2023).

Model LSTM dibangun menggunakan pendekatan *Sequential API* dari pustaka Keras. Arsitektur model terdiri atas dua lapisan LSTM bertingkat, masing-masing dengan lima puluh unit *neuron*. Lapisan LSTM pertama disusun dengan ‘return_sequences=True’ agar dapat meneruskan urutan data ke lapisan berikutnya, yang memungkinkan model mempelajari pola temporal secara menyeluruh. Lapisan LSTM kedua tidak mengembalikan urutan, melainkan menghasilkan satu vektor representasi sebagai keluaran akhir dari seluruh urutan input. Setelah itu, ditambahkan lapisan *Dense* dengan satu unit *neuron* untuk menghasilkan prediksi akhir berupa nilai Hs.

Model dikompilasi menggunakan *optimizer* Adam dan fungsi loss *Mean Squared Error* (MSE), yang umum digunakan dalam tugas regresi. Untuk menjaga performa model selama pelatihan, digunakan *callback Model Checkpoint* yang secara otomatis menyimpan bobot model terbaik berdasarkan nilai ‘val_loss’ pada data validasi. Pelatihan model dilakukan menggunakan data pelatihan yang telah dinormalisasi, dengan parameter seperti jumlah epoch dan ukuran batch yang disesuaikan agar model dapat belajar secara optimal.

2.5. Evaluasi

Tahap evaluasi dilakukan untuk mengukur performa model LSTM multivariat yang telah dibangun dalam memprediksi Hs. Evaluasi ini bertujuan untuk mengetahui sejauh mana model mampu merepresentasikan dan memprediksi pola data aktual secara akurat, serta untuk menilai efektivitas pemilihan fitur input yang telah dilakukan melalui metode korelasi Spearman.


Evaluasi dilakukan melalui dua pendekatan, yaitu evaluasi visual dan kuantitatif. Evaluasi visual dilakukan dengan memplot grafik perbandingan antara nilai aktual Hs dan hasil prediksi model pada data uji (*testing*). Grafik ini menampilkan dua garis, yaitu garis biru yang merepresentasikan nilai aktual, dan garis merah yang menunjukkan hasil prediksi dari model. Visualisasi ini berguna untuk mengamati sejauh mana model dapat mengikuti pola fluktuasi tinggi gelombang sepanjang waktu.

Selain visualisasi, dilakukan pula evaluasi kuantitatif menggunakan dua metrik utama, yaitu koefisien determinasi (R^2) dan *Mean Squared Error* (MSE). Nilai R^2 menunjukkan proporsi variansi data target (Hs) yang dapat dijelaskan oleh prediksi model, dengan nilai yang mendekati 1 menandakan performa prediksi yang sangat baik. Sementara itu, MSE digunakan untuk mengukur rata-rata selisih kuadrat antara nilai prediksi dan nilai aktual. Nilai MSE yang semakin kecil menunjukkan bahwa hasil prediksi mendekati nilai sebenarnya.

HASIL DAN PEMBAHASAN

3.1. Hasil Seleksi Fitur

Analisis korelasi Spearman dilakukan untuk mengidentifikasi variabel-variabel meteorologi dan oseanografi yang memiliki hubungan paling relevan terhadap tinggi gelombang signifikan. Grafik pada Gambar 3.1 berikut menyajikan nilai korelasi absolut antara masing-masing variabel terhadap Hs, yang digunakan sebagai dasar dalam proses seleksi fitur.



Gambar 3.1. Nilai koefisien korelasi *Spearman* antara variabel AWS dan Hs

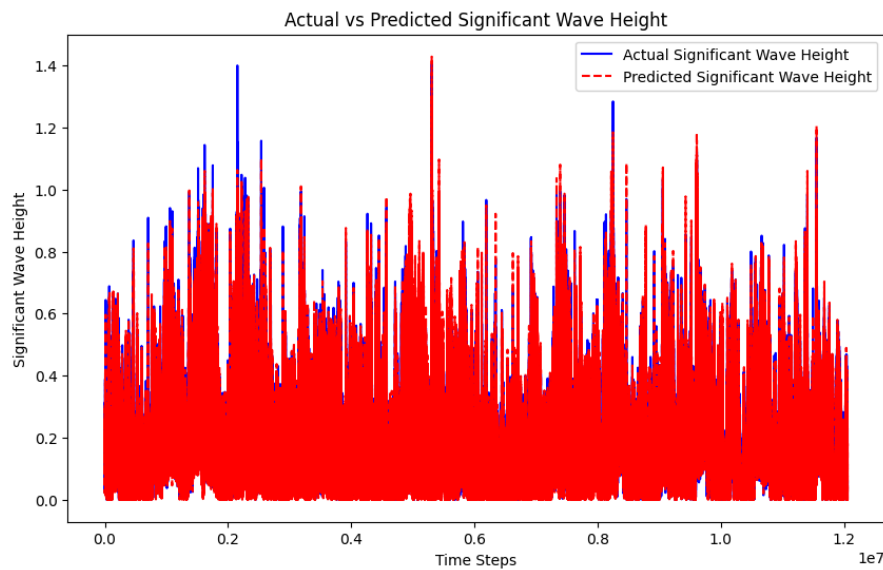
Hasil analisis korelasi Spearman antara variabel input dan tinggi gelombang signifikan disajikan pada Gambar 1. Berdasarkan grafik tersebut, kecepatan angin (*windspeed*) memiliki nilai korelasi tertinggi terhadap Hs, yaitu sebesar 0,98. Berdasarkan klasifikasi dalam metode sebelumnya, nilai ini termasuk dalam kategori sangat kuat, yang menandakan bahwa peningkatan kecepatan angin sangat berkaitan erat dengan meningkatnya tinggi gelombang. Temuan ini sejalan dengan pernyataan Sarmila (2025), yang menyebutkan bahwa variabel angin, baik kecepatan maupun arah, memiliki pengaruh dominan terhadap karakteristik gelombang laut.

Selain *windspeed*, beberapa variabel lain juga menunjukkan korelasi positif meskipun dengan kekuatan yang lebih rendah. Suhu air laut (*watertemp*) memiliki nilai korelasi sebesar 0,53 yang termasuk dalam kategori kuat, sedangkan waterlevel memiliki korelasi 0,45 dan rh (kelembaban relatif) sebesar 0,40, yang masing-masing berada dalam kategori cukup. Arah angin (*wind direction*) memiliki nilai sebesar 0,25, tergolong sangat lemah, namun tetap dipertimbangkan karena berpengaruh terhadap pembentukan gelombang laut melalui mekanisme fetch efektif, yaitu panjang lintasan angin di atas laut searah arah angin dominan (Saharti *et al.*, 2024). Selain itu, arah angin yang memiliki sifat siklis dengan rentang 0° hingga 360°, sehingga tidak dapat dianalisis secara akurat menggunakan metrik konvensional yang tidak mempertimbangkan sifat diskontinuitas pada data (Serpa-Usta *et al.*, 2025). Penelitian sebelumnya juga menunjukkan bahwa korelasi linear seperti Pearson tidak sesuai untuk data dengan karakteristik siklis (Qasem *et al.*, 2024), dan keterbatasan serupa juga dapat muncul pada korelasi berbasis peringkat seperti Spearman ketika pola siklis tidak bersifat monoton.

Sementara itu, variabel seperti suhu udara (*temp*), tekanan udara (*pressure*), radiasi matahari (*solrad*), serta beberapa parameter tambahan lainnya menunjukkan nilai korelasi yang sangat rendah, bahkan mendekati nol. Berdasarkan hasil ini, variabel-variabel tersebut dianggap tidak memiliki kontribusi signifikan dalam menjelaskan variasi tinggi gelombang signifikan dan dikeluarkan dari proses pemodelan. Hal ini didukung dengan pandangan Hidayatullah (2024), yang menyatakan bahwa perbedaan suhu dan tekanan udara dapat berkontribusi dalam pembentukan gelombang laut, namun secara keseluruhan interaksi antara angin dan permukaan laut merupakan faktor utama dalam pembentukan gelombang. Selain itu, beberapa fitur seperti *preciprate*, *ta_min*, dan *ta_max* juga tidak digunakan karena nilai korelasinya sangat rendah serta keterbatasan data di beberapa titik lokasi.

3.2. Hasil Evaluasi Model

Tahap evaluasi model dilakukan dengan membandingkan antara hasil prediksi dan data aktual tinggi gelombang signifikan pada data pengujian. Evaluasi ini ditampilkan dalam bentuk grafik (Gambar 3.2.), yang menunjukkan hubungan antara nilai aktual (digambarkan dengan garis biru) dan nilai prediksi model (digambarkan dengan garis merah putus-putus) terhadap waktu. Secara visual, grafik menunjukkan bahwa model mampu mengikuti pola umum dari fluktuasi tinggi gelombang secara konsisten, meskipun terdapat perbedaan kecil pada beberapa puncak ekstrem gelombang.



Gambar 3.2. Grafik Hasil Evaluasi Model

Untuk mengukur kinerja model secara kuantitatif, digunakan beberapa metrik evaluasi, yaitu *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2). Hasil evaluasi menunjukkan nilai MSE sebesar 0,00076, yang menandakan bahwa rata-rata kuadrat selisih antara hasil prediksi dan data aktual sangat kecil. Nilai MAE yang diperoleh adalah 0,0179, yang berarti bahwa secara rata-rata, kesalahan absolut model hanya sekitar $\pm 0,02$ meter terhadap data observasi. Sementara itu, nilai R^2 sebesar 0,9666 menunjukkan bahwa model mampu menjelaskan sekitar 96,66% dari total variabilitas data aktual, yang mengindikasikan tingkat akurasi prediksi yang sangat tinggi.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *feature selection* berbasis korelasi Spearman mampu mengidentifikasi variabel-variabel meteorologi dan oseanografi yang paling signifikan dalam mempengaruhi tinggi gelombang signifikan. Variabel kecepatan angin (*windspeed*) menunjukkan korelasi paling kuat terhadap H_s dengan nilai sebesar 0,98, diikuti oleh suhu air laut (*watertemp*), ketinggian muka air laut (*waterlevel*), kelembaban relatif (RH), dan arah angin (*winddir*) yang juga menunjukkan hubungan positif meskipun dengan tingkat korelasi yang lebih rendah. Variabel-variabel terpilih tersebut selanjutnya digunakan sebagai input dalam pemodelan menggunakan algoritma LSTM multivariat.

Hasil evaluasi menunjukkan bahwa model memiliki performa prediktif yang sangat baik, ditunjukkan oleh nilai koefisien determinasi (R^2) sebesar 0,9666, *Mean Squared Error* (MSE) sebesar 0,00076, dan *Mean Absolute Error* (MAE) sebesar 0,0179. Secara keseluruhan, penelitian ini membuktikan bahwa penerapan metode seleksi fitur berbasis korelasi Spearman pada data AWS dapat meningkatkan efisiensi dan akurasi model prediksi tinggi gelombang signifikan.

UCAPAN TERIMA KASIH

Peneliti menghaturkan banyak terima kasih kepada Universitas Pendidikan Indonesia, Program Studi Sistem Informasi Kelautan, BMKG Kota Serang, serta seluruh pihak yang telah ikut andil melalui dukungan materil maupun moril sehingga penelitian ini dapat berlangsung dengan lancar dan optimal.

DAFTAR PUSTAKA

- Akma, A. O. (2023). *Penerapan Data Mining untuk Prediksi Harga Jual Komoditas di Dinas Pertanian Kabupaten Garut* (Doctoral dissertation, Universitas Komputer Indonesia).
- Amiruddin, A., & Ishak, R. (2022). Implementasi Seleksi Fitur Klasifikasi Waktu Kelulusan Mahasiswa Menggunakan Correlation Matrix with Heatmap. *Jambura Journal of Electrical and Electronics Engineering*, 4(2), 169-174.
- Anandari, A. A. (2022). Analisis Korelasi Sektor Pertanian Terhadap Persentase Tingkat Kemiskinan dan Ketimpangan Kabupaten Jepara. *Jurnal Litbang Provinsi Jawa Tengah*, 20(1), 53-64. <https://doi.org/10.36762/jurnaljateng.v20i1.937>

- Arafat, A. F. (2021). Analisis Kinerja Pelayanan Kapal di Terminal Multipurpose Dermaga 5 Pelabuhan Ciwandan. (Tugas Akhir, Universitas Islam Indonesia). <https://dspace.uui.ac.id/handle/123456789/34443>
- Arifin, W. A., Daud, A., Maulsyid, R. P., Maulidia, R., Handyanto, L., & Sutrisno, R. A. (2025). Application Of Inverse Distance Weighted (Idw) Interpolation In Determining Wave Height In The Waters Of The Sunda Strait. *Jurnal Teknologi Perikanan dan Kelautan*, 16(3), 268-281. <https://doi.org/10.24319/jtpk.16.268-281>
- Hidayatullah, M. (2024). *Alat Pengukur Ketinggian Gelombang Air Laut Ultrasonik Dengan Sistem Internet of Things (IoT)* (Skripsi, Fakultas Teknik Universitas Sultan Ageng Tirtayasa).
- Husen, Z., Ismail, N., Surbakti, M. S., Omar, F., Yusibani, E., Kesuma, F., Nurhanif, N., Hasibuan, A. A., & Fauzi, F. (2025). Marine Automatic Weather System (MAWS) instrumentation system for climate change monitoring based on The Internet of Things (IoT). In *BIO Web of Conferences* (Vol. 156, p. 02002). EDP Sciences. <https://doi.org/10.1051/bioconf/202515602002>
- Inayah, M. E. N., Sirait, K. B., & Casie, N. (2022). Pengelompokan Produksi Telur di Provinsi Jawa Barat dengan Menggunakan Algoritma K-Means: Grouping of Egg Production in West Java Province Using the K-Means Algorithm. *SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat*, 1(1), 207-214.
- James, J. P., & Panchang, V. (2022). Investigation of wave height distributions and characteristic wave periods in coastal environments. *Journal of Geophysical Research: Oceans*, 127(5), e2021JC018144. <https://doi.org/10.1029/2021JC018144>
- Millianda, M. E., Niagara, R. G., Kemal, R., & Tsania, T. D. (2025). RANCANGAN AUTOMATIC WEATHER STATION (AWS) MENGGUNAKAN ARDUINO MEGA PADA BANDARA UNIT YANG TIDAK TERSEDIA AWS. *Jurnal TNI Angkatan Udara*, 4(3). <https://doi.org/10.62828/jpb.v4i3.159>
- Milniadi, A. D., & Adiwijaya, N. O. (2023). Analisis perbandingan model arima dan lstm dalam peramalan harga penutupan saham (studi kasus: 6 kriteria kategori saham menurut peter lynch). *SIBATIK JOURNAL: Jurnal Ilmiah Bidang Sosial, Ekonomi, Budaya, Teknologi, dan Pendidikan*, 2(6), 1683-1692. <https://doi.org/10.54443/sibatik.v2i6.798>
- Mudho, H. T., & Pranowo, W. S. (2023). Perumusan Karakteristik Gelombang Perairan Halmahera Utara dan Morotai: Characteristic Formulation of Waves in The North Halmahera and Morotai Coastal Waters. *Jurnal Hidropilar*, 9(2), 103-116. <https://doi.org/10.37875/hidropilar.v9i2.294>
- Mustofani, D., & Hariyani, H. (2023). Penerapan Uji Korelasi Rank Spearman Untuk Mengetahui Hubungan Tingkat Pengetahuan Ibu Terhadap Tindakan Swamedikasi Dalam Penanganan Demam Pada Anak. *UJMC (Unisda Journal of Mathematics and Computer Science)*, 9(1), 9-13.

- Nurhalijah, S. D., Nina, C., Romadhona, A., Maulani, N., & Rahayu, M. S. (2024). Analisis Korelasi Spearman Untuk Mengetahui Hubungan Antara Penggunaan Media Sosial Dan Tingkat Produktivitas Akademis Mahasiswa Agribisnis (Studi Kasus: Universitas Sultan Ageng Tirtayasa). *Jurnal Ilmiah Wahana Pendidikan*, 10(16), 800-809.
- Ouyang, Z., Gao, Y., Zhang, X., Wu, X., & Zhang, D. (2024). Significant Wave Height Forecasting Based on EMD-TimesNet Networks. *Journal of Marine Science and Engineering*, 12(4), 536. <https://doi.org/10.3390/jmse12040536>
- Pamungkasih, P. (2023). Penerapan uji korelasi rank Spearman untuk mengetahui hubungan pengeluaran rumah tangga untuk makanan dan tingkat kemiskinan di Nusa Tenggara Timur selama pandemi Covid-19. *Jurnal Statistika Terapan (ISSN 2807-6214)*, 3(02), 1-12.
- Putra, A. F. R., Hertika, A. M. S., & Maimunah, Y. (2025). Hubungan Kelimpahan Mikroplastik dengan Kerusakan Histopatologis Pada Insang dan Usus Udang Vaname (*Litopenaeus Vannamei*) yang Dibudidayakan di Tambak di Probolinggo, Jawa Timur, Indonesia. *Jurnal Riset Akuakultur*, 20(1), 63-77.
- Putra, F., Tahiyat, H. F., Ihsan, R. M., Rahmadden, R., & Efrizoni, L. (2024). Penerapan Algoritma K-Nearest neighbor Menggunakan wrapper Sebagai preprocessing Untuk Penentuan Keterangan Berat Badan Manusia: application of K-Nearest neighbor algorithm using wrapper as preprocessing for determination of human weight information. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(1), 273-281.
- Qasem, H., Joergensen, N. E., Rahman, A., Samman, H. A., Al Malki, S., & Al Ansari, A. S. (2024). Vine Copula-Based Multivariate Distribution of Rainfall Intensity, Wind Speed, and Wind Direction for Optimizing Qatari Meteorological Stations. *Water*, 16(9), 1257. <https://doi.org/10.3390/w16091257>
- Saharti, S., Lilipory, I., & Pattiselanno, S. R. (2024). Penentuan Parameter Gelombang Laut Berdasarkan Data Angin yang Mengacu Pada ECMWF (European Centre For Medium-Range Weather Forecast) di Perairan Dusun Waeyoho, Desa Kawa, Kab. Sbb. *Journal Agregate*, 3(2), 96-101.
- Sarmila, S. (2025). Analisis Peramalan Tinggi Gelombang Laut Menggunakan Metode Shore Protection Manual (SPM) dan Darbyshire di Pantai Pangali-Ali, Kabupaten Majene Sulawesi Barat (Doctoral dissertation, Universitas Sulawesi Barat).
- Suandewi, N. M. A., Muliantara, A., & Raharja, M. A. (2023). Pengembangan Sistem Database Lokasi Automatic Rain Gauge (ARG) dan *Automatic Weather Stations* (AWS) Berbasis Website di Balai Besar MKG Wilayah III Denpasar. *Jurnal Pengabdian Informatika*, 1(4), 1153-1160.
- Serpa-Usta, Y., Flores, D. L., López-Ramos, A., Fuentes, C., Muñoz-Muñoz, F., González Tejada, N. M., & López-Lambraño, A. A. (2025). Hybrid Deep Learning Models for Predicting Meteorological Variables Associated with Santa Ana Wind Conditions in

the Guadalupe Basin.
<https://doi.org/10.3390/atmos16111292>

Atmosphere, 16(11), 1292.