

双方向ConvLSTMを用いた 日本周辺海域の高精度波浪予測

新潟大学大学院自然科学研究科
社会基盤・建築学コース（社会基盤系）

青木 雄大, ○中村 亮太

研究背景

■ 有義波高予測の重要性


- 安全で効率的な港湾運営，船舶の安全航行支援．海洋資源開発の計画・運用．海岸構造物の設計・施工判断．津波・高潮など沿岸防災への活用．

■ 従来手法：数値波浪モデル（Wave Watch III (WWIII)、SWAN）

- 物理法則に基づく高い信頼性，全球～沿岸域まで幅広く利用

○ 課題

- 計算コストが非常に大きい，高性能計算機（HPC）が必要



日本海波浪の数値計算．約8か月の計算に，16コアPC(3.7Ghz)で1週間を要する。

■ 深層学習による波浪予測

大量の波浪・気象データから予測パターンを学習．学習後は極めて高速に推論可能．数値モデルと比較して最大1000倍高速化との報告．Tiら(2024)は、西太平洋12年分の波浪予測を数秒で実施．

➡ 高精度な波浪予測を維持しつつ、リアルタイム予測や大規模アンサンブル予測を実現する手法として深層学習が注目されている．

既往研究

■ 時系列予測モデルの発展

SVM・逐次学習：初期の機械学習手法，**長期依存関係**の学習が困難.

LSTM：**波高時系列予測**で高精度，多くの研究で従来手法を上回る.

BiLSTM + **Attention**：極端気象下でも精度向上，空間情報の利用が限定的.

時系列情報(過去情報)を残す手法の進化.

より最近

Attention is all you need (Vaswani et al. 2017)

■ 時空間情報を考慮した深層学習手法

CNN：波浪場の空間特徴を抽出.

CNN-LSTM：空間＋時間特徴を**同時学習**.

CNN-BiLSTM：長期依存・**非線形性**の表現能力向上.

Ti et al.：風速場→波浪場の面的予測を実現.

複雑な波浪及び他の物理場との面的関係性の学習が可能となる.

より最近

■ 実用化に向けた課題

入力変数の最適化：波高のみ vs 風速＋波高風予報誤差の影響

日本沿岸への適用性：複雑な海岸線・海底地形日本海側と太平洋側で異なる波浪特性

長期予測性能：多くの研究は24時間以内72時間先予測の信頼性は未解明

本研究の目的

■ **研究目的**：日本海沿岸で、**双方向ConvLSTM (BiConvLSTM)** を用いた**有義波高予測モデルの有効性**を体系的に評価する。

- **着目点**：日本沿岸は地形・海域特性が複雑。波浪場の時間変動も複雑。
双方向構造により時系列依存関係をより適切に学習可能

■ 研究概要

- **データ対象期間**：2000～2024年, **対象領域**：日本沿岸海域,
- **入力変数**：**波高のみ** / **波高 + 風速**
- **感度分析条件**：入力時系列長 (WS) 6 h, 12 h, 24 h
- **リードタイム (LT)**：1 h, 6 h, 12 h, 24 h, 36 h, 72 h

■ 検証項目

- ①日本沿岸の複雑な地形条件下での適用性。②海域特性の違いに対する予測性能。
- ③風速入力長期予測精度へ与える影響。④72時間先予測における精度維持能力。

研究手法① (対象領域・使用データ)

■ 対象領域

- ・ 日本周辺海域 (範囲: $25\text{--}50^{\circ}\text{ N}$, $125\text{--}150^{\circ}\text{ E}$)
- ・ 日本海側と太平洋側の双方を含む日本沿岸の複雑な地形・海域特性を対象

■ 使用データ (ERA5 再解析データ変数)

- ・ Swh: 有義波高, u10: 10 m高度の東西風速, v10: 10 m高度の南北風速. 時間分解能: 1時間. 風速成分を波浪格子へ線形内挿. 格子状時系列データとして整備

■ データ期間と分割区分

- ・ 学習期間 2000/1/1 – 2015/12/31
- ・ 検証期間 2016/1/1 – 2019/12/31
- ・ テスト期間 2020/1/1 – 2024/12/31




図-1 対象海域の格子構成 (北緯25-50度, 東経125-150度) .

研究手法②

■ データ前処理・標準化（海域マスクの作成）

- swh が有限値の格子点：海域 = 1
- それ以外：陸域 = 0
- 入力チャネルおよび損失関数に適用
- 陸域の誤差を学習・評価から除外
- 欠損値処理マスク抽出後，欠損値を 0 で補完
- zスコア標準化の式は式(1)
- 対象変数：swh, u10, v10
- 平均 μ ・標準偏差 σ は学習期間のみから算出
- 欠損値は除外して推定海域マスクは標準化しない。

$z_{t,i,j}^{(k)} = \frac{x_{t,i,j}^{(k)} - \mu^{(k)}}{\sigma^{(k)}}$	(1)
$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + b_i)$	(2)
$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + b_f)$	(3)
$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + b_o)$	(4)
$g_t = \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c)$	(5)
$C_t = f_t \odot C_{t-1} + i_t \odot g_t$	(6)
$H_t = o_t \odot \tanh(C_t)$	(7)

■ BiConvLSTMモデル

- 時間依存関係と空間特徴を同時に学習
- 日本沿岸の複雑な波浪変動に対応
- ConvLSTMにより格子構造を保持したまま時空間特徴を抽出
- 順方向ConvLSTM：過去から現在へ処理
- 逆方向ConvLSTM：入力系列を逆順に走査
- * 逆方向処理は未来情報を用いるものではない




図-2 BiConvLSTMの概略図。

研究手法③

■ 入力データと予測対象

- 入力系列：式 (9) , 予測対象：式 (10)
- WS：入力時系列長. LT：予測リードタイム
- 現在時刻までの履歴から将来の有義波高分布を予測

$$X = \{x_{t-WS+1}, \dots, x_t\} \quad (9)$$

$$Y = y_{t+LT} \quad (10)$$

■ 評価指標

- RMSE： 誤差の大きさ (式 12)
- R^2 : 空間分布の再現性 (式 13)

$$RMSE = \sqrt{\frac{1}{N_{sea}} \sum_{i,j} (y_{i,j} - \hat{y}_{i,j})^2 \cdot M_{i,j}} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i,j} (y_{i,j} - \hat{y}_{i,j})^2 \cdot M_{i,j}}{\sum_{i,j} (y_{i,j} - \bar{y})^2 \cdot M_{i,j}} \quad (13)$$

感度分析評価・計算環境		学習設定	
WS	6, 12, 24 h	損失関数	Masked MSE
LT	1, 6, 12, 24, 36, 72 h	Optimizer	Adam
Case 1	swh + ocean mask	学習率	1×10^{-3}
Case 2	swh + u10 + v10 + ocean mask	Hidden size	64
Framework	PyTorch 2.9.0	層数	2
CUDA	12.9	Dropout	0.1
GPU	NVIDIA RTX 5090	最大Epoch	100

* 本研究の特徴

- ①海域のみを対象に評価 (Masked MSE) .
- ②将来の気象予報値は使用しない.
- ③履歴情報のみから72時間先まで予測.
- ④風速入力の有効性を公平に比較.

研究結果①

■ リードタイム LT の影響

・ RMSE

持続モデル (Persistence) は LT の増加に伴い急激に悪化
Case2 (波高 + 風速) は高い予測精度を維持。

・ R^2

LTの増加に伴い低下するが、持続モデルおよび既往研究を上回る性能 $\Rightarrow$ Case2 (WS=24 h) は全LTで最も高精度。




図-3 予測リードタイムLTに対するRMSEおよび R^2 の推移 (WS = 24 h). (a) RMSE, (b) R^2 .

■ 入力時系列長 WS の影響

・ RMSE・ R^2 の比較

6 h	LT $\geq$ 24 hで精度低下
12 h	精度が大幅に改善
24 h	12 hとほぼ同等主な結果

WS = 6 $\rightarrow$ 12 h : RMSE低下, R^2 向上

WS = 12 $\rightarrow$ 24 h : 改善効果は小さい $\Rightarrow$ 波浪発達・減衰の予測には約12 hの履歴情報が重要




図-4 入力時系列長に関する感度解析 (Case2). (a) RMSE, (b) R^2 .

研究結果②

■ R^2 の空間分布 (図-5, 図-6)

- ・ Case2はCase1 (波高のみ) より全体的に高い
 - ・ R^2 を示した特に日本海側および沿岸近傍海域で改善が顕著
- リードタイム別の特徴

6 h	ほぼ全域で $R^2 = 0.90-1.00$
24 h	日本海側・太平洋沖合で $R^2 = 0.70-0.90$
72 h	全体的に低下するがCase1より高精度

■ 代表地点における時系列再現性 (図-7)

- ・ 対象地点：北緯39.5° 東経150° (波浪変動が最も大きい地点)

LT	R^2	再現性
6 h	0.982	周期的な波高変動やピーク時期を良好に再現
24 h	0.732	波形傾向を概ね再現 (ばらつきが増加)
72 h	0.232	高波浪を過小評価 (4.5 m以上の高波浪を十分に予測できない)

→ 長期予測では極端波浪の再現性が課題




図-5 決定係数 R^2 の空間分布比較 (WS = 24 h).




図-6 全海域における観測値 (ERA5) と予測値の相関分析 (WS = 24 h).

研究結果③

■ 観測された高波浪場解析領域南部（140° E, 30° N付近太平洋沖）で、10 m超の高波浪域を観測

- ・ 周辺には 4–8 m の高波浪域が広い分布テスト期間中の最大波高事例

■ リードタイム別の予測結果

6 h	高波浪域の位置・広がり・極大値を良好に再現
24 h	高波浪域の位置は再現するが極大値を過小評価
72 h	高波浪域中心が消失し分布が平滑化

■ 空間分布の比較

LT = 6 h	高波浪域の位置を正確に再現周辺海域への広がりも良好
LT = 24 h	波浪分布の大局的構造は維持極大波高は低く推定
LT = 72 h	高波浪域の中心が消失最大波高は2–4 m程度に低下極端波浪を大幅に過小評価




図-7 代表地点（北緯39.5度，東経150度）における予測性能の検証結果。左列は時系列，右列は散布図。




図-8 最大波高観測時（2021年9月30日）における有義波高分布の比較。

考察

■ 風速入力の効果

・ Case2（波高＋風速）が全リードタイムで最高精度

- ① LTが長くなるほどCase1との差が拡大.
- ② 風速履歴により波浪の発達・減衰過程を表現可能.
- ③ 日本海・太平洋沖合で特に効果が顕著 → 長期予測では風速入力が有効.

■ 入力時系列長（WS）の影響

- ① 6 h：長期予測で精度低下.
- ② 12 h：高精度かつ計算効率良好.
- ③ 24 h：12 hとほぼ同等

■ 高波浪時の再現性

- ① LT = 24 h：高波浪域の位置は再現.
- ② LT = 72 h：極大波高を過小評価
LTが長いと予測場が平滑化 → 長期予測では極端波浪の再現が課題

■ 海域マスクの効果

- ① 陸域を損失計算から除外.
- ② 沿岸地形の影響を低減.
- ③ 日本海側・沿岸域でも比較的高精度.
→ 複雑な沿岸地形を含む海域で有効

■ 限界と今後の課題

- ① Multi-shot予測.
- ② 将来風速場の導入.
- ③ 極端波浪の再現性向上

まとめ

■ 本研究の成果

- ① BiConvLSTMの有効性：日本沿岸を対象とした波浪予測に適用LTの増加に伴い精度は低下するものの、 $LT = 24 \text{ h}$ で $R^2 \approx 0.77$ を維持。既往研究を上回る予測性能を確認。 → 24時間先程度までの予測に有効。
- ② 風速入力の効果：有義波高に加えて風速 (u_{10}, v_{10}) を入力。日本海側および太平洋沖合で精度向上。長いLTほど改善効果が顕著。 → 風の履歴情報は波浪発達・減衰の表現に重要
- ③ 入力時系列長 (WS) の影響： $WS = 6 \rightarrow 12 \text{ h}$ でRMSE改善・ R^2 向上。 $WS = 12 \text{ h}$ と 24 h の差は小さい。 → $WS = 12 \text{ h}$ が精度と計算効率の両面で有力。
- ④ 高波浪時の再現性： $LT = 24 \text{ h}$ では高波浪域の位置・広がりを概ね再現。 $LT = 72 \text{ h}$ では極値を過小評価し分布が平滑化。 → 短中期予測には有効だが長期予測には改善の余地。

参考文献

- Ahn, S., Tran, T., and Kim, J.: Systematization of short-term forecasts of regional wave heights using a machine learning technique and long-term wave hindcast, *Ocean Engineering*, Vol. 264, 112593, 2022.
- Jing, Y., Zhang, L., Hao, W., and Huang, L.: Numerical study of a CNN-based model for regional wave prediction, *Ocean Engineering*, Vol. 255, 111400, 2022.
- Ti, Z., Song, Y., and Deng, X.: Spatial-temporal wave height forecast using deep learning and public re-analysis dataset, *Applied Energy*, Vol. 326, 120027, 2022.
- Berbic, J., Ocirk, E., Carevic, D., and Loncar, G.: Application of neural networks and support vector machine for significant wave height prediction, *Oceanologia*, Vol. 59, No. 3, pp. 331-349, 2017.
- Kumar, N., Savitha, R., and Al Mamun, A.: Regional ocean wave height prediction using sequential learning neural networks, *Ocean Engineering*, Vol. 129, pp. 605-612, 2017.
- 小原裕貴, 中村亮太: LSTMを用いた日本海側の高精度波浪予測, 土木学会論文集B3 (海洋開発), 第77巻, 2号, 1_751-1_756, 2021. [Obara, Y. and Nakamura, R.: High-precision wave prediction using LSTM on the Sea of Japan, *Journal of Japan Society of Civil Engineers, Ser. B3 (Ocean Engineering)*, Vol. 77, No. 2, pp. 1_751-1_756, 2021.]
- Bethel, B., Sun, W., Dong, C., and Wang, D.: Forecasting hurricane-forced significant wave heights using a long short-term memory network in the Caribbean Sea, *Ocean Science*, Vol. 18, No. 2, pp. 419-436, 2022.
- Fan, S., Xiao, N., and Dong, S.: A novel model to predict significant wave height based on long short-term memory network, *Ocean Engineering*, Vol. 205, 107298, 2020.
- Jörges, C., Berkenbrink, C., and Stumpe, B.: Prediction and reconstruction of ocean wave heights based on bathymetric data using LSTM neural networks, *Ocean Engineering*, Vol. 232, 109046, 2021.
- Luo, Q., Xu, H., and Bai, L.: Prediction of significant wave height in hurricane area of the Atlantic Ocean using the Bi-LSTM with attention model, *Ocean Engineering*, Vol. 266, 112747, 2022.
- 西田航平, 小原裕貴, 中村亮太: LSTM-マルコフ連鎖モデルを用いた日本沿岸域における有義波高予測の検討, 土木学会論文集B3 (海洋開発), 第78巻, 2号, 1_457-1_462, 2022. [Nishita, K., Obara, Y., and Nakamura, R.: Prediction of significant wave height in Japanese coastal areas using an LSTM-Markov chain model, *Journal of Japan Society of Civil Engineers, Ser. B3 (Ocean Engineering)*, Vol. 78, No. 2, pp. 1_457-1_462, 2022.]
- Bai, G., Wang, Z., Zhu, X., and Feng, Y.: Development of a 2-D deep learning regional wave field forecast model based on convolutional neural network and the application in South China Sea, *Applied Ocean Research*, Vol. 118, 103012, 2022.
- Zhang, J., Luo, F., Quan, X., Wang, Y., Shi, J., Shen, C., and Zhang, C.: Improving wave height prediction accuracy with deep learning, *Ocean Modelling*, Vol. 188, 102312, 2024.
- Jörges, C., Berkenbrink, C., Gottschalk, H., and Stumpe, B.: Spatial ocean wave height prediction with CNN mixed-data deep neural networks using random field simulated bathymetry, *Ocean Engineering*, Vol. 271, 113699, 2023.
- Wu, Y., Wang, J., Zhang, R., Wang, X., Yang, Y., and Zhang, T.: RIME-CNN-BiLSTM: A novel optimized hybrid enhanced model for significant wave height prediction in the Gulf of Mexico, *Ocean Engineering*, Vol. 312, 119224, 2024.
- Obara, Y. and Nakamura, R.: Transfer learning of long short-term memory analysis in significant wave height prediction off the coast of western Tohoku, Japan, *Ocean Engineering*, Vol. 266, 113048, 2022.
- Song, T., Han, R., Meng, F., Wang, J., Wei, W., and Peng, S.: A significant wave height prediction method based on deep learning combining the correlation between wind and wind waves, *Frontiers in Marine Science*, Vol. 9, 983007, 2022.
- Hersbach, H., Bell, B., Berrisford, P., Biavati, G., Horányi, A., Muñoz Sabater, J., Nicolas, J., Peubey, C., Radu, R., Rozum, I., Schepers, D., Simmons, A., Soci, C., Dee, D., and Thépaut, J.-N.: ERA5 hourly data on single levels from 1940 to present, Copernicus Climate Change Service (C3S) Climate Data Store (CDS), DOI: 10.24381/cds.adbb2d47, accessed January 25, 2026, 2023.
- Meng, Z., Chen, Z., Khoo, B., and Zhang, A.: Long-time prediction of sea wave trains by LSTM machine learning method, *Ocean Engineering*, Vol. 262, 112213, 2022.
- Vaswani, A., et al. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.