

畳み込みニューラルネットワークを用いた波浪予測手法の開発

Development of wave prediction method using deep convolutional neural network

板谷 知明^{*1}
Tomoaki Itaya

岩前 伸幸^{*1}
Nobuyuki Iwamae

^{*1} 鹿島建設株式会社
Kajima Corporation

Wave prediction is important for maritime construction works. This study investigated the possibility of wave prediction by deep convolutional neural networks using numerical weather prediction model data as input. This method predicts wave heights from grid data of mean sea-level pressure p , wind velocity u and v . 4 networks were trained for different forecast lead times 0, 6, 12, 24 hours. As a result, 12, 24 hours networks, in spite of their longer lead times, gave good prediction in terms of RMSE and sensitivity for detection of high waves whose heights were over 1.0 m.

1. はじめに

港湾や洋上風力発電などの海上工事において、作業船による施工を行う際、その地点の波高が高いと施工の実施が困難な場合がある。現在は、現場の作業関係者が、気象庁や民間の気象予報会社が提供する気象・海象の予報データから経験的に施工の可否を判断しているが、それらの予報は、施工可否の決定境界が存在すると考えられる有義波高 0.5~1m 付近の予測に特化したものではない。また、工事地点のピンポイントな波浪予測として利用するには、空間解像度が粗い。

近年、ニューラルネットワーク (Artificial Neural Networks; ANN) の技術的な進歩を背景として、特定地点に対するピンポイントな波浪予測手法として ANN を用いた研究が増加している [津田 2017, 五十嵐 2018a など]。中でも気象数値予報モデルによる面的な気象データを使用した研究には [Traccey 2018, 五十嵐 2018b など] があるが、これらは主として全結合型の ANN を使用したものであり、一般に面的な入力データに対して使用されることが多い畳み込みニューラルネットワーク (Convolutional Neural Networks; CNN) を含む様々な手法に対する検討が十分になされているとは言えない。

波浪は、その場所の風によって形成される風浪と遠隔地の気象の影響が複雑な過程を経て伝播し形成されるうねり性波浪の重ね合わせである。後者の影響を考慮した波浪予測を行うためには、遠隔地を含んだ気象データを面的に解析する必要があり、そのようなデータに対して、どのようなアーキテクチャの ANN が有効であるのかを検討することは重要であると考えられる。

本研究では、気圧配置など気象場の空間構造をとらえた予測が期待できる CNN を用いて、気象数値予報モデルの面的なデータを入力とした波浪予測手法を開発し、観測データを使用して検証を行った。

2. CNN による波浪予測手法

2.1 予測の枠組み

時刻 t の気象場を入力に、リードタイムを L [hr] として、ある地点の時刻 $t + L$ の有義波高を予測する。

気象場と波浪の関係性を CNN に学習させるにあたって、気象モデルの予報バイアスの影響を取り除くため、学習には観測データを用いて過去の気象場を再現した客観解析データを使

用する。ただし、運用する際は、未来の気象予報データを入力に使用して運用する予定である。予報データにはすでに現在時刻からのリードタイムが存在するため、必ずしも、予報データに対してさらに波高予測のリードタイムを確保する必要はない。

2.2 ネットワーク構造

畳み込みの層数の多い深い構造にしても学習が容易であり、現在よく使用されている Resnet を採用した。今回は CNN の適用性の検証が主な目的であることから、Resnet の中では比較的浅い 10 個の residual block (building block) を持つ構成とした。出力層は、有義波高を出力する 1 ニューロンの全結合層とした。

2.3 最適化手法

波高予測にあたっては、施工可否の分かれ目となる 0.5~1m 付近の有義波高に関心があり、2m 以上の大きな波に対しては、2m 以上の予測値を出していれば十分である。そのため、大きな誤差に強く影響されない損失関数である $\log(\cosh(x))$ を使用した。バッチサイズは 32 とし、オプティマイザーは adam を使用した。過学習抑制のため、Early stopping により検証データに対する平均二乗誤差の低下が止まった段階で学習を打ち切った。

3. 実験設定

3.1 気象データ

(1) 概要

気象庁 GSM (日本域) 客観解析データを使用した。領域は東経 110~160 度、北緯 10~60 度、格子系は、等緯度等経度、経度 0.25 度×緯度 0.2 格子 (格子数 201×251) である。解析時刻は 0, 6, 12, 18 時 (UTC) である。気象場の状態を表す代表的な変数として、海面更正気圧 p と風速 u, v の 3 チャネルをモデルへの入力データとした。

(2) 前処理

まず、実運用時に入力として使用することになる気象庁 GSM 予報データのグリッドに合わせて、東経 120~150 度、北緯 20~50 度の領域 (格子数 121×151) を切り出した。

次に、画像として扱えるよう各チャネルを最小値 0, 最大値 1 になるよう正規化し、線形補間により格子数を 128×128 とした (図 1)。




図 1. 画像化された入力データ例
a) 風速 u, b) 風速 v, c) 海面更正気圧 p

3.2 波浪データ

(1) 概要

ナウファス(全国港湾海洋波浪情報網)から、秋田港の有義波高の観測データを使用した。観測間隔は 20 分である。

(2) 前処理

気象データの時間間隔と合わせるため、ダウンサンプリングを行い、6 時間ごとの観測値を抽出した。

3.3 学習・検証・テスト方法

学習・検証に使用するデータの期間は、2010 年から 2014 年までの 5 年間とし、学習・検証に使用するデータの比率が 0.8 対 0.2 になるようランダムサンプリングを行い、学習・検証データを作成した。テストに使用するデータの期間は、2015 年の 1 年間とした。

3.4 リードタイム

予測のリードタイムは、0, 6, 12, 24 時間とし、それぞれ別々のネットワークとした。

3.5 開発環境

AWS の GPU インスタンス ml.p2.8xlarge にて学習した。プログラムの実装には、深層学習ライブラリ Keras を使用した。

4. 結果

4.1 計算時間

各リードタイムのモデルについて、1 モデル 20 分程度の学習時間で early stopping により学習が完了した。

4.2 リードタイムによる予測精度の比較

波浪予測モデルに求められる精度には、平均的な予測誤差が小さいことに加えて、施工可否の判断の境目となる有義波高を超えるかどうかを正確に予測できることが求められる。そこで、各モデルのテストデータに対する RMSE に加えて、有義波高が閾値 1.0m をを超えるかどうかを予測できたかどうかについて、「正解が 1.0m 以上のときにモデルが 1.0m 以上と予測したものの割合」である再現率(recall)と、「モデルが 1.0m 以上と予測したもの

表 1. モデルのリードタイムと有義波高予測精度

Model Lead time [hr]	0	6	12	24
TEST RMSE [m]	0.657	0.568	0.471	0.485
TEST RECALL	77.0%	78.4%	80.7%	86.0%
TEST PRECISION	75.6%	76.4%	93.7%	81.9%

のうち、実際に正解が 1.0m 以上であるものの割合」である適合率(precision)を求め、モデルを評価した(表 1)。

RMSE は、リードタイムが 12 時間のとき最も低く、次に、24 時間、6 時間、0 時間と RMSE が高くなっていった。再現率は、リードタイムが長いほど高く、24 時間が最も高かった。適合率は、リードタイム 12 時間が最も高く、RMSE と同様の順位であった。

4.3 予測バイアスの特性

各モデルのテスト時の予測時系列の例を図 2 に示す。どのモ




図 2. 各モデルの予測時系列の例(2015 年 9 月)
青線:観測値, 赤線:予測値, 黒点線:波高 1.0 m
リードタイム:a) 0 時間, b) 6 時間, c) 12 時間, d) 24 時間

デルも、波高のピークはある程度とらえていた。特に、リードタイム 24 時間のモデルは、9 月 4 日付近のピークにやや遅れがみられるが、9 月 12 日付近のピークは唯一遅れることなく予測できていた。波高が 1.0m 以下の平常時については、リードタイム 0, 6 時間のモデルは、過大評価しがちであるが、リードタイム 12, 24 時間のモデルは、良好に予測できており、波高のピーク時と平常時とで、メリハリのついた予測ができていた。

5. 考察

5.1 リードタイムと精度

0, 6 時間後予測より 12, 24 時間後の波浪予測の方が予測精度が高かった理由は、近傍の気象の影響を受けて波浪が形成されるまでに時間がかかること(時間的遅れ), 及び、入力データに含まれる遠隔地の気象情報が、予測対象地点に伝播するまでに時間がかかること(空間的遅れ)を反映していると考えられる。

再現率と適合率については、再現率は 24 時間後予測の方が高く、適合率は 12 時間後予測の方が高かった。施工の安全性という観点からは、見逃しの少ない 24 時間後予測モデルの方が

有用であり、工事の遅延を防ぐという観点からは、空振りの少ない12時間後予測モデルの方が有用であると考えられる。

現場で使用する際は、以上のようなモデルの特性を考慮して、用途に合ったモデルを使用することが必要であると考えられる。

5.2 他手法と比較した本手法の利点

波浪予測手法には、物理過程から波浪を予測する波浪推算モデルもあるが、日々の波浪予測に使うには計算コストが高い。本手法は、ANNを用いているため、モデルの学習には多少時間がかかるが、一度学習すれば、推論は短時間で可能であり、日々の予測への利便性が高い。また、損失関数などを操作することで、対象地点において運用する際のニーズに合わせて予測精度やバイアスのチューニングをすることが可能である。

また、本手法を実際に運用する際には、入力気象予報モデルの予報値に差し替えればよい。気象庁GSM(日本域)予報では、現在、予報時間0～84時間について、1時間間隔の予報データを1日4回配信している。従って、例えば、本研究の12時間後波浪予測モデルに対して、このデータを入力として使用すれば、12,13,14,...,96時間後と、現在から12時間後以降については、1時間ごとの有義波高の予測値を得ることができる。ただし、その際は気象予報モデル自体が持つ誤差が予測に加わるので、その影響を別途検証する必要がある。

さらに、本手法は、総観規模の広域の気象場を入力に予測を行うため、うねり性波浪の予測や、低気圧の接近などの予測地点における未来の気象の変化を考慮した波浪予測が可能であると考えられる。全結合型のANNでは、このような広域の面的気象場を入力とすると、パラメータの数が多くなり、より多くの計算資源を必要とする上、気圧配置などの入力の位置の変化に対する頑健性を確保するのがより難しくなると考えられる。今回は特定のうねり性波浪や低気圧などのイベントに対する検証ができなかったため、今後の課題となる。

6. おわりに

本研究では、波浪予測に対するCNNの適用性を検証するため、面的な気象データを入力に、ある地点の波高を予測するCNNを開発した。

気象数値予報モデルの客観解析データと波浪観測データを用いた検証実験を行い、予測のリードタイムを何時間とるかが波高の予測精度に影響を与え、必ずしもリードタイムが短いほど予測精度が高まるわけではないことを示し、データと目的によって、適切なリードタイムの設定が必要であることを明らかにした。

今後は、他地点への適用のほか、実際の海上工事の現場管理への適用に向け、今回訓練したモデルに気象数値予報モデルの予報値(客観解析データのように予報後に取得した観測データによる事後的な補正を受けていないもの)を入力とした検証実験を行う予定である。その場合、気象予報モデルのリードタイムに、それを入力とする波浪予測モデルのリードタイムを足したものが実際のリードタイムとなるため、どちらにどの程度のリードタイムを配分するかの検討が必要であると考えている。

謝辞

波浪観測データとして、ナウファス(全国港湾海洋波浪情報網: NOWPHAS: Nationwide Ocean Wave information network for Ports and Harbours)のデータを使用しました。ナウファスは国土交通省港湾局・各地方整備局・北海道開発局・沖縄総合事務局・国土技術政策総合研究所および港湾空港技術研究所の相互協力のもとに構築・運営されている我が国沿岸の波浪

情報網です。気象庁GSM(日本域)客観解析データは、一般財団法人気象業務支援センターに提供して頂きました。

参考文献

- [津田 2017] 津田宗男, 松見吉春, 金洙列, 松田信彦, 江口三希子: 円滑な海上施工管理のための波浪と作業船の動揺のリアルタイム予測, 土木学会論文集 B2(海岸工学), 73 巻 2 号, p. I_151-I_156, 2017.
- [五十嵐 2018a] 五十嵐雄介, 今井聡, 伊東敦史, 海津博行: ニューラルネットワークによる簡易的な波浪推定方法についての検討, 土木学会論文集 B2(海岸工学), 74 巻 2 号, p. I_679-684, 2018.
- [Tracey 2018] Tracey H. A. Tom, 間瀬肇, 池本藍, 斎藤武久, 川崎浩司, 武田将英: 日本海上の気象データを用いたニューラルネットワークによる日本海沿岸の波浪予測, 土木学会論文集 B2(海岸工学), 74 巻 2 号, p. I_691-696, 2018.
- [五十嵐 2018b] 五十嵐雄介, 田島芳満: ニューラルネットワークによる日本沿岸の波浪の推定に関する検討, 土木学会論文集 B2(海岸工学), 74 巻 2 号, p. I_685-690, 2018.