

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 a Wave Prediction Method Using Deep Convolutional Neural Networks

板谷 知 明 岩 前 伸 幸 新 保 裕 美

要 約

海上工事において、作業船による施工の可否は波高の影響を受けるため、事前に波高が予測できると施工管理上有用である。本研究では、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を開発し、観測データを用いて本手法の精度検証を行った。気象庁 GSM（日本域）客観解析データの海面更正気圧 p と風速 u, v の 3 チャンネルの面データを入力とし、0, 6, 12, 24 時間後の秋田港の有義波高を別々のネットワークで予測した。RMSE 及び 0.5, 1.0, 2.0 m 以上の波の検出率についての再現率と適合率を用いて評価を行ったところ、12, 24 時間後の予測精度は、0, 6 時間後よりも高く、特に損失関数を MSE としたときには、0.5, 1.0m 以上の波浪については 80~90%、2.0m 以上の波浪については 70~80% 程度の再現率・適合率で予測が可能であった。以上から、本手法の有効性が示された。

目 次

- I. はじめに
- II. CNN による波浪予測手法
- III. 実験設定
- IV. 結 果
- V. 考 察
- VI. おわりに

I. はじめに

海上工事において、作業船による施工の可否は波高の影響を受けるため、事前に波高が予測できると管理がしやすい。通常は、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することが多いが、それらの予報は、作業限界が存在すると考えられる有義波高（例えば、0.5~2.0 m）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）技術の進歩を背景として、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。例えば、予測対象地点の波浪データと周辺の気象観測点の気象データを入力として全結合型 ANN による波浪予測を

行った研究¹⁾や、気象数値予報モデルの面的な気象データを入力として全結合型 ANN による波浪予測を行った研究²⁾³⁾があるが、面的な気象データを入力として、面的な入力データの空間構造をとらえることができる畳み込みニューラルネットワーク（Convolutional Neural Networks; CNN）を使用して波浪予測を行った研究はない。

波浪は、その場所の風によって形成される風波と遠隔地から伝播するうねり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、遠隔地を含む気象データを入力する必要があるが、その際に点データを入力とすると、点どうしの空間的な位置関係を ANN に考慮させることが困難になり、波浪を形成する要因である気象場の空間構造がとらえられなくなる。したがって、面的なデータを入力する必要があるが、その場合でも、全結合型の ANN では面内の点どうしの位置関係の情報が入力されなくなる。

本研究では、面的な入力データ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本手法の精度検証を行った。

II. CNN による波浪予測手法

本章では、ANN 及びその一種である CNN について述べた

キーワード: 波浪予測, 気象, 機械学習, 畳み込みニューラルネットワーク

Keywords: wave prediction, meteorology, machine learning, convolutional neural network

後に、本研究での CNN の適用手法について述べる。

1. ANN の概要

ある入力（例えば、地表面風速）に対して、ある出力（例えば、有義波高）を対応付ける関数を求めたいとする。このとき、入力変数の数が少なく、また、入出力が単純な線形の関係にあれば、線形重回帰分析などの手法によって関数を構成することが効果的であると考えられるが、入力変数の数が多く、また、入出力関係も非線形と考えられる場合には、より複雑な関数を構成する必要がある。ANN は、そのような複雑な関数を構成する手法の一つである。

ANN は、生物の神経ネットワークの構造を模倣したもので、単純な関数であるニューロン（一つの神経細胞に相当する）の集合によって複雑な関数を構成するものである。ANN のうち、順伝搬型ニューラルネットワークは、入力層・中間層・出力層から構成される (Fig.1)。入力信号は、入力層から




Fig.1 ANN の概要 (Artificial Neural Network)




Fig.2 ANN のニューロン (A Unit of ANN)




Fig.3 CNN における畳み込み層とプーリング層 (Convolutional Layer and Pooling Layer in Convolutional Neural Networks)

中間層を経て出力層へと一方向に順伝播する。各層は複数のニューロン (Fig.2) を持ち、各ニューロンが前層のニューロンの出力を入力として受け取り、式 (1) (2) によって記述される処理を行った後に、次の層のニューロンへ出力する。

$$u = \sum_i^I w_i x_i + b \dots \dots \dots (1)$$

$$z = f(u) \dots \dots \dots (2)$$

ここで、 I は前層のニューロンの数、 x_i は前層の i 番目のニューロンの出力、 w_i は x_i に対する重み係数、 b はバイアス、 $f(u)$ は活性化関数、 z は出力である。活性化関数には様々な関数を使用されるが、本研究では、中間層が多い順伝搬型ニューラルネットワークで使用されることが多い ReLU 関数

$$f(u) = \max(u, 0) \dots \dots \dots (3)$$

を使用した。

正解入出力のセットを学習データとして用意すれば、それに適合するように各ニューロンの重み係数とバイアスを決定することによって、学習データにおけるデータの入出力関係を近似する関数を表現することが可能である。

2. CNN の概要

Fig.1 のように、各層のニューロンがその前後の層のすべてのニューロンと結合している層を全結合層という。画像などの面的なデータは、空間的に限られた領域が意味的なまとまりとなっているため、全結合層のみを持つ全結合型の ANN が使われることは稀で、畳み込み層・プーリング層を持つ CNN (Fig.3) が使用されることが多い。

畳み込み層における各ニューロンは、縦横位置 i, j と出力チャンネル番号 m を持ち、座標 (i, j, m) 上に存在している。前層のチャンネル数を K とすると、チャンネル番号 m のニューロンは、サイズ $H \times H \times K$ の共通のフィルタを持ち、前層から入力される信号に対して、式 (1) の代わりに、式 (4) によって記述される畳み込み演算を行う。

$$u_{ijm} = \sum_{k=0}^{K-1} \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} w_{pqk} x_{i+p, j+q, k} + b_m \dots (4)$$

ここで、 k が入力チャンネル番号、 H がフィルタの縦横のサイズ、 w_{pqk} がフィルタの重み係数、 $x_{i+p, j+q, k}$ が前層の座標 $(i+p, j+q, k)$ のニューロンの出力である。畳み込み演算は、入力内のある領域に対するフィルタの内積を求める処理に相当し、入力がフィルタの記憶している形状と同じ形状を持つかどうかを検出する機能を持つ。

プーリング層は、畳み込み層の直後に設置される層であり、畳み込み層の出力に対して、位置感度を低下させる処理を行うことで、入力の位置の変化に対する頑健性を高める機能を持つ。チャンネル m 内において、座標 (i, j, m) を中心とする $H \times H$ の正方領域をとり、そこに含まれるニューロンの出力を P_{ijm} とすると、プーリング層の出力は、式(5)によって表される。

$$z_{ijm} = g(P_{ijm}) \dots (5)$$

ここで、 $g(P_{ijm})$ は関数であり、 P_{ijm} の最大値を出力する関数(max pooling)や平均値を出力する関数(average pooling)などが使用される。本研究では、max poolingを使用した。

3. 予測の枠組み

本研究の波浪予測の枠組みを Fig.4 に示す。気象数値予報モデルから時刻 t の気象場のデータを取得し、前処理を行った後、CNN に入力し、リードタイムを L [hr] とし、工事地点の時刻 $t+L$ の有義波高を予測する。時刻 t の気象場が入力データ、時刻 $t+L$ の有義波高が出力データであり、CNN はそれらの入出力関係を学習することになる。画像と同様に、気象場は低気圧などのまとまりのある空間構造をもつため、本研究では、全結合型 ANN ではなく CNN を用いた。

4. ネットワークアーキテクチャ

ネットワークは、畳み込み層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 ResNet⁴⁾を採用した。畳み込み層は 26 層とした。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。

5. 最適化手法

学習データからランダムにサンプリングを行い、そのサンプル(ミニバッチ)に対して、誤差の大きさを示す損失関数

の勾配を誤差逆伝播法により求め、勾配方向へパラメータの更新を行うという処理を繰り返す確率的勾配降下法によって、パラメータの最適化を行った。

波浪予測にあたっては、施工可否の分かれ目となる比較的低い波浪(例えば、有義波高 0.5~2.0 m 程度)の予測に関心があり、施工可否の分かれ目を大きく超える波に対して正確な波高を予測する必要はない。そのため、大きな誤差に強く影響されない $\log(\cosh(x))$ と平均 2 乗誤差 (Mean Squared Error; MSE) の 2 つの損失関数を使用し、結果を比較した。ミニバッチのサイズは 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 MSE の低下が止まった段階で学習を打ち切った。

III. 実験設定

1. 気象データ

(a) 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 \times 緯度 0.2 格子 (格子数 201 \times 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 (東西成分)、 v (南北成分) の 3 チャンネルをモデルへの入力データとした。

(b) 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 \times 151) を切り出した (Fig.5)。次に、各チャンネルを最小値 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 \times 128 とした (Fig.6)。

2. 波浪データ

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 (Fig.5)。

データ間隔は 20 分である。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. 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




Fig.4 予測の枠組み
(Framework of Wave Prediction Method)

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。

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。

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。

IV. 結果

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

習時間で学習が完了した。

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2乗平均平方根誤差 (Root Mean Squared Error; RMSE) に加えて、有義波高が閾値0.5, 1.0, 2.0mを超えるかどうかを予測できたかどうかについて、「正解が閾値以上のときにモデルが閾値以上と予測したものの割合」である再現率 (recall) と、「モデルが閾値以上と予測したもののうち、実際に正解が閾値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 (Table 1)。RMSEは、リードタイムが12時間のとき最も低く、0.471m (損失関数 logcosh), 0.439m (損失関数 MSE) であり、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・適合率は、12, 24時間後の予測精度が0, 6時間後よりも高かった。特に、損失関数がMSEのとき、0.5, 1.0m以上の波浪については80~90%、2.0m以上の波浪については70~80%程度の再現率・適合率で予測が可能であった。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、損失関数がlogcoshの場合はリードタイム12時間が最も高く、損失関数がMSEのときは、24時間後が最も高かった。

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 Fig.7 に示す。どのモデルも、波高のピークについては、値が過小評価のみであるものの、タイミング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11日午前6時のピークは唯一遅れることなく予報できていた。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



Fig.5 入力データ範囲(気象)と秋田港の位置 (Area of Meteorological Input Data and Akita Port)




Fig.6 入力データ例

a) 風速の東西成分 u, b) 風速の南北成分 v, c) 海面更正気圧 p
 (An Example of Input Data a) wind speed u, b) wind speed v, c) sea surface pressure)

Table 1 モデルのリードタイムと有義波高予測精度
(Lead time, Loss Function and Prediction Accuracy)

Model Lead Time [hr]	0		6		12		24	
Loss Function	logcosh	mse	logcosh	mse	logcosh	mse	logcosh	mse
RM SE [m]	0.657	0.651	0.568	0.564	0.471	0.439	0.485	0.471
Recall 0.5 m	88.6%	86.9%	86.4%	83.8%	81.1%	86.7%	90.4%	88.9%
Precision 0.5 m	71.9%	73.9%	75.2%	79.1%	87.6%	82.7%	78.5%	84.5%
Recall 1.0 m	76.8%	77.0%	78.5%	75.1%	80.5%	84.5%	86.0%	86.6%
Precision 1.0 m	75.4%	72.4%	76.2%	83.7%	93.7%	83.0%	81.9%	85.7%
Recall 2.0 m	55.0%	61.1%	69.2%	54.5%	59.7%	72.5%	66.8%	74.4%
Precision 2.0 m	82.3%	77.2%	74.5%	84.6%	92.0%	76.9%	87.0%	79.7%




Fig.7 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 (損失関数 logcosh)，緑線：予測値 (損失関数 MSE)，黒点線：波高 1.0 m, 黒一点鎖線：2015年9月11日午前6時
 リードタイム：a) 0時間, b) 6時間, c) 12時間, d) 24時間
 (Prediction Time Series in September 2015
 observation(blue), prediction(logcosh:red, MSE:green)
 lead time: a) 0 hours, b) 6 hours, c) 12 hours, 24 hours)

であるが、リードタイム 12、24 時間のモデルは、比較的良くに予測できており、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。損失関数の違いによって各

ピークの予測の精度は異なるものの、どちらの精度が良いかはピークによって異なり、系統的な違いは見られなかった。

V. 考察

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、本手法が気象情報だけを入力としており、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) を反映したためと考えられる。

再現率と適合率は、損失関数やリードタイムによって異なる結果となったが、施工の安全性という観点からは、見逃しの少ない再現率の高い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、空振りの少ない適合率の高い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。

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、日々の波浪予報に使うには計算負荷が大きい。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、日々の予報への利便性が高い。また、今回は検討しなかったが、過小評価ペナルティを与えるなど、損失関数を操作することで、対象地点において運用する際のニーズに合わせて予測誤差の傾向をチューニングすることが可能である。

さらに、本手法は総観規模の広域の気象場を入力として予測を行うため、うねりの予測や、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。今回はうねりや台風などの特定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。

VI. おわりに

本研究では、面的な気象データを入力とする CNN による波浪予測手法を開発した。

また、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、データや目的によって、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、特定のうねりイベントや、学習データの少ない台風などの稀な事象における波浪予測精度の検証を行う予定である。

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。

参考文献

- 1) 津田宗男ほか；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，2017，pp. I_151-I_156.
- 2) Tracey H. A. Tom ほか；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，2018，pp. I_691-696.
- 3) 五十嵐雄介ほか；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，2018，pp. I_685-690.
- 4) He et al. ; Deep Residual Learning for Image Recognition, In CVPR, 2016.

Development of a Wave Prediction Method Using Deep Convolutional Neural Networks

Tomoaki Itaya, Nobuyuki Iwamae and Yumi Shimbo

Wave prediction is important for maritime construction works. Recently, several studies have shown the effectiveness of artificial neural networks for point wave prediction from meteorological grid data. However, it remains to be elucidated whether convolutional neural networks (CNNs) are effective or not, although CNNs are widely used for analysis of grid data. This study investigated the possibility of wave prediction by CNN using numerical weather prediction model grid data as inputs. This method predicts future wave heights at a target point from grid data of mean sea-level pressure p , wind velocity u and v . In order to test the method, significant wave height at Akita Port was predicted. Four networks were trained for different forecast lead times of 0, 6, 12 and 24 hours. As a result, the 12- and 24-hour models, in spite of their longer lead times, gave good predictions in terms of RMSE and recall/precision for waves of over 0.5, 1.0, and 2.0 m. The best model had recall/precision rates of over 80% for waves of over 0.5 and 1.0 m, and over 70% for waves of over 2.0 m. These results confirm the effectiveness of the CNN-based wave prediction method.