

# 深層学習による海象の多変量時系列予測

長岡技術科学大学院 環境社会基盤工学専攻 水圏防災工学研究室 ○久々江耀平  
長岡技術科学大学院 環境社会基盤工学専攻 水圏防災工学研究室 細山田得三

## 1. 序論

近年の水災害の甚大化<sup>1)</sup>を受け、海岸工学分野をはじめとして、より正確かつ高速な予測技術が求められている。数時間から3日程度先の短中期の波浪予測は、船舶運航や水圏の工事等の可否判断、高波のリアルタイム把握に用いられる。特に中期の波浪予測は全球モデルGPV<sup>2)</sup>により行われているが、空間解像度が荒く、各地点における細やかな予測はなされていない。そのため工事施工判断のための波浪予測としては不十分である。

そこで、本研究では短中期の波浪予測の手段として深層学習の適用を提案する。

### (1) 海岸工学分野における深層学習

こうした短中期の波浪予測においては、物理モデルの代替として深層学習を用いて予測の高速・高性能化を図る事例<sup>3)</sup>がある。アプローチは事例により様々であるが、最も簡便なものは過去の観測値（表形式データ）を入力とした回帰分析である。しかし、ANN（Artificial Neural Network）やCNN（Convolution Neural Network）を用いることが多く、時間依存を考慮するアルゴリズムを組み込んだ事例は少ない。

機械学習、深層学習において入力とするデータは特徴量と呼ばれ、一般にこれらを何らかのアルゴリズムを利用して作成、選択し、予測精度を向上させる。

また、近年ではモデルの解釈性・説明性が重視され、特徴量と予測値の関係性を説明するための手法が注目されている。

しかし、これらを波浪予測に適用した事例は無く、近年主となっている手法での機械学習・深層学習の効果や適用性は検討されていない。このため、まずは簡便な事例を取り扱い、深層学習の適用性を検討すべきである。

### (2) 近年の深層学習

古典的機械学習ではなく、深層学習を適用する利点として入力データの多様性が挙げられる。他分野では画像の入力や物理モデルとのハイブリットモデルなど従来よりも高度な運用がなされている。

近年のこうした高度な深層学習モデルのデファクトスタンダードとして、Transformerが挙げられる。Transformerの最も注目すべき点はAttentionと呼ばれる仕組みにある。Attentionは入力系列間の関連度（Attention Weight）を算出し、どのデータに注目すべきかを学習する機構である。Transformerに限らず、Attention機構を採用した深層学習モデルは、近年のあらゆるサービスに利用され、高い機能を持つ。元は自然言語処理分野の技術であるが、時系列予測には共通する点が多く、Attention機構の適用性が示唆されている<sup>4)</sup>が未だ事例は少ない。

また、OptunaやRay Tuneなど最適化ライブラリを用いて自動的にハイパーパラメータを決定することが知られている。人力でのハイパーパラメータチューニングは、適切な組み合わせを見落とす可能性があるため積極的にこうしたライブラリを利用すべきである。

### (3) 目的

波浪予測における深層学習の運用は、画像からの予測や生成、物理モデルとのハイブリット、それらのシステム化などより高度なものが考えられる。

本研究では、より高度に深層学習を運用し、短中期の波浪予測を行うための第一段階として、簡便な表形式データを入力とし、深層学習モデルによる多変量時系列予測を行なった。さらに適切にハイパーパラメータチューニング、特徴量選択を行うことで予測精度向上を図った。

## 2. 実験概要

本研究では、現時点から数時間前の観測値から数時間～数日先の有義波・波高を2時間ごとに予測する多変量時系列予測を行う。目的変数は新潟港の有義波・波高、入力した特徴量は新潟港を含めた日本海沿岸のNOWPHAS観測値である。計算環境としてPython, Pytorch, Cudaを用いた。

### (1) 対象地点・期間

対象としたNOWPHAS観測所は留萌港、青森西岸沖、新潟港、伏木富山港伏木、輪島港、柴山港、藍島港である。観測期間は2014年～2018年を対象とした。このデータは日本海側観測所のデータの内、過度に欠測値が多いものを排除した結果である。

### (2) 特徴量

Pytorchを用いた深層学習による計算では、モデルに入力する配列をテンソルとして扱う。本研究において入力としたテンソル型は(ミニバッチサイズ, 入力シーケンス長, 変数)である。対象期間中のデータから訓練データ・検証データ・評価データを6:2:2の割合で分割した。

### (3) モデル作成

一般に深層学習を用いた時系列予測には、RNN (Recurrent Neural Network) 系モデルを使用することが多い。RNN系のアルゴリズムは逐次的な計算により時系列依存を考慮する。そのため、必要に応じて過去の情報を忘却する機能がある。しかし、海象予測においては台風によるトレンド的な変化を考慮する必要があり、年に数回しか来襲しない台風の影響を適切に学習するには、数年に渡り過去の情報を保持する必要がある。この問題の解決策のとして図-1に示すTransformer<sup>5)</sup>による時系列予測が考えられる。Transformerは時系列依存の考慮の際、時間情報を特徴量とする。そのため、RNN系モデルのように逐次計算を必要とせず、離れたのトレンド同士を同列に扱うことができる。故に年に数回しか来襲しない台風の傾向を複数年分のデータから十分に学習することができる。

以下にTransformerの特に重要なアルゴリズムTime2VecとAttentionを説明する。

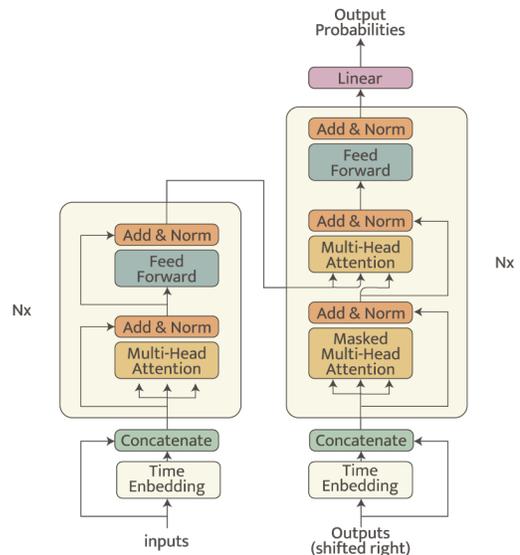


図-1 Transformerモデルのアーキテクチャ

#### a) Time2Vec

入力データとそのステップに対してsin波とcos波、線形式に基づき付与し、それらを深層学習モデル同様に学習により変化させることで、時間を表現する特徴量空間を形成するアルゴリズム<sup>6)</sup>である。

出力されるテンソル型は入力テンソルに結合するため(バッチサイズ, 入力シーケンス長, 変数 (+非周期性, 周期性))である。

#### b) Attention

Attentionは学習により重要な値であるか否かを適切に決定していくアルゴリズムである。初めに入力テンソルを $q$ : Query,  $k$ : Key,  $v$ : Valueとして複製し、NN (Neural Network) に入力する。この時、NNの出力層によって変数の値が変動する。次に式(1)にそれぞれのテンソルを入力し、Attention Weightを算出する。 $d_k$ は入力の次元である。式中のQueryとKeyの内積はベクトル同様、値が大きいほど近い向きであり、入力内で重要な値となる。Attention Weightが適切に入力と出力を説明できるように学習することで通常のNNより高い精度が見込める。

$$\text{softmax}\left(\frac{\mathbf{q} \times \mathbf{k}^T}{\sqrt{d_k}}\right) \times \mathbf{v} \quad (1)$$

#### (4) ハイパーパラメータチューニング

ハイパーパラメータのチューニングはRay TuneライブラリのOptunaアルゴリズムに基づき行った。その結果を表-1に示す。

表-1 ハイパーパラメーター一覧

ハイパーパラメータ	値
予測シーケンス長	2, 24, 48, 72(hour)
入力シーケンス長	96(hour)
バッチサイズ	128
エポック	50
学習率	1e-6
最適化手法	AdamW
損失関数	MSELoss

表-2 各特徴量の SHAP 値

地点名	SHAP 値
留萌港	7.11e-5
青森西岸沖	-1.71e-5
新潟港	4.41e-5
伏木富山港伏木	2.62e-5
輪島港	-1.37e-5
柴山港	9.79e-5
藍島港	2.08e-5

表-3 各特徴量の SHAP 値

予測シーケンス長	RMSE	
	選択前	選択後
2hour	0.170	0.166
12hour	0.366	0.268
24hour	0.496	0.416
48hour	0.580	0.634
72hour	0.700	0.726

### (5) モデル解釈と特徴量選択

SHAP (SHapley Addictive exPlanations) は予測の平均値とあるステップの予測値の差について各特徴量の占める割合を求める手法<sup>7)</sup>である。SHAP 値はこの計算の全ステップの平均である。本研究では、SHAP 値によって予測に貢献する特徴量を選択することでモデルの軽量化、精度向上を図る。

## 3. 結果と考察

### (1) 全特徴量を用いた波浪予測

図-2 に代表例として全特徴量から学習し、予測シーケンス長 12hour, 72hour とした際の 2018 年 10 月から 2 ヶ月間の波浪予測を示す。また、表-3 に各予測シーケンス長の RMSE (2 乗平均平方根誤差) を示す。予

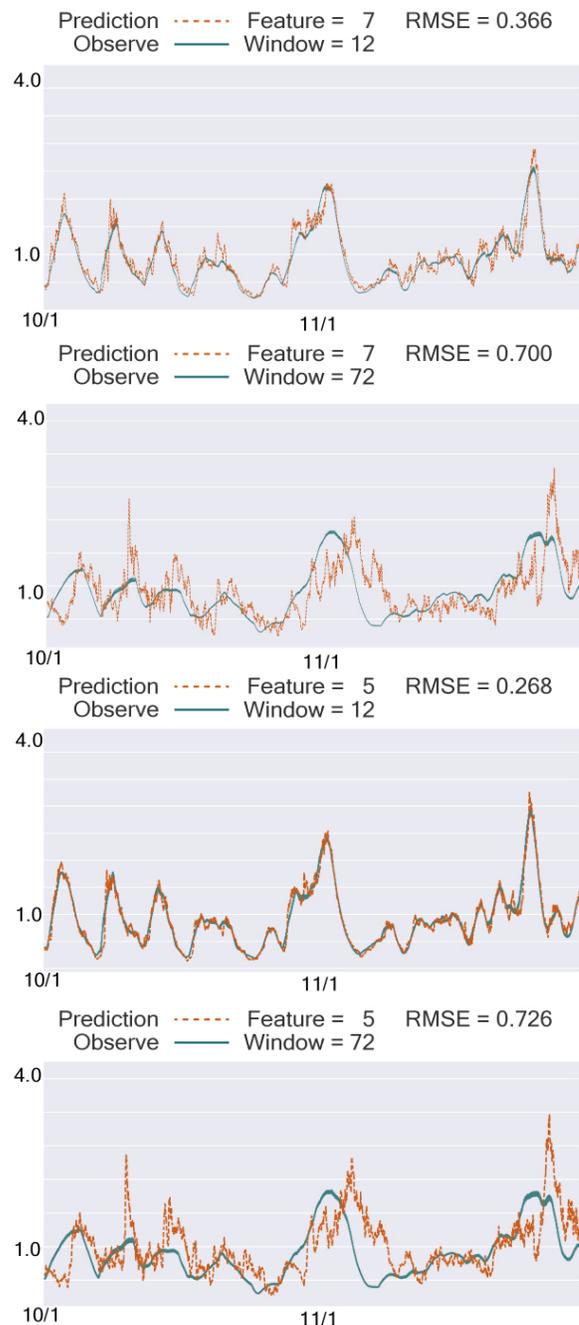


図-2 波浪予測結果

測シーケンス長 72hour のグラフに顕著になっているが、予測シーケンス長 24hour 以上では波高の変化を過大に評価する傾向にある。一方で 12hour 予測では観測値とほぼ一致していることからモデルの適用性は高いといえる。

### (2) SHAP による特徴量選択

表-2 に代表例として予測シーケンス長 24hour の検証データをモデルに入力した際の SHAP 値を示す。

他に予測シーケンス長を 2hour, 12hour, 48hour, 72hour に変化させているが、傾向は一致しており、青森西岸沖と輪島港の SHAP 値は極端に低く、予測精度を低下させていると判断した。また、柴山港と留萌港、新潟港はいずれの条件でも SHAP 値が高く強い因果関係が推察される。

### (3) 特徴長選択後の波浪予測

特徴量選択を行なった後の波浪予測の RMSE を表-3 に示す。また、2018 年 10 月から 2 ヶ月間の波浪予測の結果を図-1 に示す。

RMSE は、24hour 以内の予測シーケンス長では改善している。しかし、48hour 以上の予測シーケンス長になると RMSE は特徴量選択前よりも悪化している。

このことから中期予測にはより多くの特徴量を以って説明する必要があるが、短期予測は少ない特徴量の方が、良い結果を得られることが分かった。

## 4. 総括

本研究では、波浪予測における深層学習の高度な運用の前段階として、表形式データを用いた基本的な多変量時系列予測を行った。

特に Attention 機構の時系列予測への適用性、SHAP による特徴量選択、ライブラリによるハイパーパラメータ決定の自動化を行い、予測精度向上を図った。

その結果、次のことが結論づけられる。Attention 機構およびそれを主としたモデルでも時系列予測が可能である。SHAP によりモデルの予測値と特徴量の関係を推し量ることができる。一部条件はあるが、SHAP を参考にした特徴量選択で予測精度を改善することができる。

また、本研究の課題として次のことが挙げられる。観測値では入力となるデータが少ない。欠測が多いため、観測値以外を入力データを用意する。SHAP によりどの特徴量が予測に対して重要であるか、つまりモデルがどの特徴量を重視しているかということは判明したが、それをさらに説明するためには物理的な海洋モデルなどで結果を近似する必要がある。

以上のことを改善し、より予測精度とモデルの解釈性を向上させた上で、モデルの高度化を図る。

謝辞：本研究を行うに当たり、NOWPHAS データを使用致しました。ここに感謝の意を表します。

## 参考文献

- 1) 森信人, 岩嶋亮太, 安田誠宏, 間瀬肇, Tracey H. Tom : 地球温暖化予測に基づく全球の海上風・波浪の将来変化予測, 土木学会論文集 B2 (海岸工学), Vol.65, No.1, pp1271-1275, 2009
- 2) 間瀬肇 : 全球波浪予報値と機械学習法を用いた 1 週間先までの高精度日本沿岸波浪予測モデルの開発, (一財) 港湾空港総合技術センター平成 31 年度 研究開発助成 成果報告書, 第 20-7 号, 2019
- 3) 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), Vol.74, No.2, pp685-pp690, 2018
- 4) 本田良司, 小笠原範光, 小玉亮 : Transformer による時系列予測, 人工知能学会全国大会論文集, 2020.
- 5) [Vaswani 17] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Kukasz Kaiser, Illia Polosukhin : "Attention is all you need.", In NIPS'17
- 6) [Kazemi 19] Seyed Mehran Kazemi, Rishab Goel, Sepehr Eghbali, Janahan Ramanan, Jaspreet Sahota, Sanjay Thakur, Stella Wu, Cathal Smyth, Pascal Poupart, Marcus Brubaker: "Time2Vec: Learning a Vector Representation of Time", In CoRR
- 7) [Lundberg 17] Scott Lundberg, Su{-}In Lee : "A unified approach to interpreting model predictions", In NIPS'17
- 8) 国土交通省港湾局 : 全国港湾海洋波浪情報網波浪データ, <http://www.mlit.go.jp/kowan/nowphas/>, 参照 2021-10-14.