

高潮予測のためのディープニューラルネットワーク構築に関する検討と自己組織化マップを用いた評価

九州大学 学生会員 ○清水功基
 九州大学 児玉充由
 九州大学 正会員 井手喜彦
 九州大学 フェロー 橋本典明

1. 目的

温暖化が進むと海面水温の上昇により、強い台風の発生頻度が現在に比べて高くなることや海面が上昇することが指摘されている。そのため、高潮災害への対応の重要性はさらに高まっていくと考えられ、より迅速で正確な判断のための高潮予測が求められている。現在、高潮予測には数値モデルによるシミュレーションが主流となっているが数値シミュレーションでは計算精度と計算速度がトレードオフの関係にあり双方を両立させるのは難しい。そこで本研究では、数値シミュレーションに代わってディープニューラルネットワーク(DNN)を使用した高潮予測の可能性に注目した。DNN モデルは高精度な数値シミュレーションを前もって学習させることでその数値シミュレーションの精度を維持したまま高速で高潮予測を行うことができる。例えば、この高速な計算を活かすと台風経路の不確実性を考慮したアンサンブル実験を行い、確率論的な高潮予測や台風の最悪経路の選定が可能となることが考えられる。したがって、本研究では気象データを用いた高潮予測のための DNN の構築に関する検討を目的とする。

2. 内容

2-1. 使用データの概要

DNN モデルの構築には非常に多くのデータが必要なため「地球温暖化対策に資するアンサンブル気候予測データベース(d4PDF)」を用いた。まず、経度 130~133 度、緯度 32~35 度で囲まれる領域(図 1 の小領域)を通る台風を d4PDF から抽出した。それらが経度 128~138 度、緯度 30~36.6 度で囲まれる領域(図 1 の大領域)に存在している間の毎時の気圧、風分布を外力として数値シミュレーションを行い、高潮偏差を得た。なお、シミュレーションモデルには周防灘での高潮に関して十分な精度を有する園田ら¹⁾によって構築された Finite Volume Community Ocean Model を用いた。




図 1 各領域

2-2. DNN モデルの概要

DNN モデルは入力層、出力層、およびその中間に配置される複数の隠れ層からなる回帰モデルを使用した。入力層には図 1 の赤破線で囲む領域(DNN 領域)の気象データ(気圧・風)を入力する(格子数 31(緯度方向)×54(経度方向))。ただし、各格子の毎時の気象データを全て入力すると計算コストが膨大になることに加え、台風毎に台風が領域内に存在する時間が異なるため一つのモデルでは対応できない。したがって、気圧であれば、対象期間における各格子の最小値分布を入力データとして与えた。例えば、図 1 に示す台風経路であれば気圧の入力データは図 2 のようになり、台風の経路上で気圧が低くなることがわかる。風についても同様に東西および南北風速の分布(u,v)を作成し、データに与えた。しかし、これらの入力だけでは高潮を考慮する際に重要となる台風の移動速度の情報が含まれていない。そのため、台風が各格子内へ滞在した時間の空間分布も入力データとして使用した。したがって、構築した DNN モデルの入力ノード数は 31×54(格子数)×4(入力分布数)=6696 である。なお、出力層は 1 ノードで宇部の最大高潮偏差とし、テストデータは 100 個とした。




図 2 最低気圧分布の例

2-3. DNN モデルの最適化に関する検討

2-3-1. ハイパーパラメータ

重み、活性化関数および学習率の決定法を変化させ、二乗平均平方根誤差(RMSE)を確認し、適したパラメータを決定した。その結果、重みは gauss, 活性化関数は Parametric ReLU, 学習率は Nesterov momentum を設定した。

2-3-2. 最適領域

DNN に使用する最適な領域を決定するため、領域を変えた Case0~Case10 で精度を比較した。Case0 (図3のDNN初期領域)は東経128~138度、北緯30.0~36.5度。Case1~Case9はCase n に対して東経 $128+0.3n$ ~ $138-0.7n$ 度、北緯 $30+0.4n$ ~ $36.6-0.1n$ 度のように宇部を中心に領域を狭めていき、最小領域のCase10は東経131~131.4度、北緯33.8~34.0度まで領域を絞った(図3)。図4にRMSEの領域依存性を示す。最も精度がよいケースはCase1である。Case1より広域のCase0では情報が多いが精度が落ちている。これは、重みの数が増え更新頻度が減るためだと思われる。また、Case3以降の精度が落ちたのは採用領域が狭いため必要な情報が十分に含まれていないためと考えられる。これより、本研究の最適なDNN領域はCase1と結論付けた。




図3 DNN 領域




図4 RMSE の領域依存性




図5 RMSE のデータ数依存性

2-3-3. 入力データ数と種類

入力データ数の増加と精度の依存性を確認するため、訓練データ数を徐々に増加させた(図5)。概ね訓練データ数が増加するとRMSEが減少したがデータ数が200を超えるとRMSEの変化は小さくなり、データ数1200のときRMSEが最小となった。次に、入力ノード数を少なくすることでDNNの学習計算コストを減らすために気圧分布、風分布、台風が各格子内へ滞在した時間の空間分布の中でいずれか一つを使用しない場合を検討した。その結果、RMSEはそれぞれ7.94cm, 8.53cm, 6.87cmであった。全分布を使用した場合は6.46cmであることから計算コストの大きさが問題になる場合は台風が各格子内へ滞在した時間の空間分布を省いてもよいと考えられる。

3. 自己組織化マップを用いたDNNモデルの検討

高潮偏差の小さな台風データの数が多いことによるテストデータの偏りを減らし、適切なRMSEを得ることや本研究のDNNモデルの特徴を検討するために自己組織化マップ(SOM)を用いた。SOMを用いて台風を最低気圧気圧分布をもとに25パターンに分けた(図6)。次に25パターンそれぞれから4つつつテストデータを出し計100個をテストデータとした。このテストデータを用いてRMSEを求めた結果6.53cmを示し、これを本研究の最小RMSEとした。また、テストデータの偏りを減らしていない場合の最小RMSEが6.46cmでありRMSEの変化が少ないことが分かる。このことから本研究のDNNモデルの精度の最低気圧の位置や強度への依存性は低いと考えられる。




図6 SOMによる台風の分類

4. 結論

本研究ではDNNモデルの最適なハイパーパラメータや領域の設定、データの種類や数のほか、中間層についても検討した。また、SOMを用いることでテストデータの偏りを減らし、適切なテストデータで本研究のDNNモデルの精度は台風経路や台風強度への依存性が低いことを確認した。その結果、RMSEは最小で6.53cmを示した。

参考文献

- 1) 園田ら(2019): 周防灘における将来の高潮に関する研究, 土木工学論文集 B2 (海岸工学), Vol.71, No.2, I_1183-I_1188.