

## ディープラーニングによる風速の短期予測方法の高精度化

愛媛大学大学院 学生会員 ○今村実 愛媛大学大学院 正会員 全邦釘  
愛媛大学大学院 正会員 藤森祥文 愛媛大学大学院 正会員 森脇亮

### 1. はじめに

風速は不規則な現象のため数秒先であっても将来予測をすることが難しい。相原・森脇(2014)<sup>1)</sup>は小規模風車のパワーアシスト機能への応用を想定して数秒先の風予測を試みており、ニューラルネットワークの一つである自己組織化マップ(SOM)を用いた風予測では、1秒先の予測の精度は高いが、将来の先の予測になるほど予測精度は低くなることを報告している。本研究では近年注目を集めるディープラーニングに注目した。ディープラーニングは、人工知能が学習データの特徴を読み取ることができ、複雑な特徴も表現することができるという特性を持つ。一方、風の流れは非線形現象であるが組織的な乱流構造に伴う一定の風速変動パターンも内在している。この知見を利用して学習方法(人工知能への学習のさせ方)に工夫を加えることで予測精度の向上にも期待できる。そこで、本研究では、風速の短期予測へのディープラーニングの適用可能性を検討すること、風速の乱流特性を考慮した最適な学習方法を検討することを目的とする。

### 2. 研究方法

本研究ではディープラーニングを使用し風速の水平成分  $u$ (以下  $u$ )の観測値から将来の  $u$  を予測する。予測にはディープラーニングモデルの一つである LSTM(Long Short - Term Memory)<sup>2)</sup>を用いた。LSTM とは教師あり学習アルゴリズムの内、多層ニューラルネットワークを用いたディープラーニングモデルの一種である。LSTM は時系列データの特徴を取り扱うことに長けており、データの長期に亘る記憶を実現できることが特徴である。LSTM は中間層間が結合したネットワーク形をしており、中間層内のメモリユニットによりユニットの形を記憶、または忘却しながら学習が行われる(図1)。

本研究は連続する 50000 秒の風速データを研究対象とした。50000 秒の内最後の 3600 秒(1時間)を評価期間とする。対象の風速データは観測に三次元超音波風速計(GILL 社, Wind Master II)を使用し、愛媛大学工学部 2号館屋上で観測したものをを用いた。使用した風速計の写真を図2に示す。図1において、風速の観測値が入力データ  $X$ 、予測された将来の風速値が出力データ  $y$  である。出力データは以下の式(1)を用いて得る。

$$y^t = f^{(out)}(W^{(out)}z^t) \quad (1)$$

ここで、 $y^t$ : 出力データ、 $f^{(out)}$ : 活性化関数、 $W^{(out)}$ : 中間層と出力層間の重み、 $z^t$ : メモリユニットからの出力を表す。

本研究では予測精度向上のため、二つの乱流特性に着目した。一つ目は、レイノルズ応力による  $u$  と風速の鉛直成分  $w$ (以下  $w$ )の関係である。乱流の場合  $u$ ,  $w$  の変動成分  $u'$ ,  $w'$  は、 $u' < 0$  のとき  $w' > 0$ ,  $u' > 0$  のとき  $w' < 0$  という負の相関関係がある。この  $u$  と負の相関関係を持つ  $w$  を学習データに加えることで予測精度の向上に期待ができる。二つ目は、乱流の組織的な周波数構造である。乱流は組織的な構造であるため、風速はある周波数帯にピークを持つ。周波数を考慮して風速の履歴を学ばせることで予測精度の向上に期待できる。

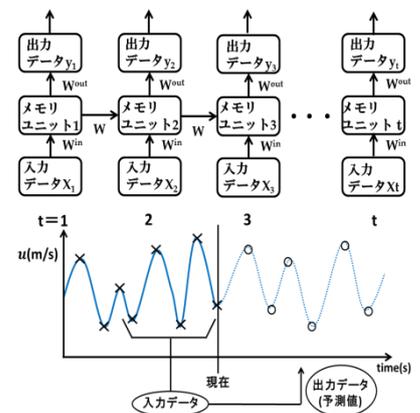


図1 LSTMの仕組み



図2 三次元超音波風速計

### 3. 結果と考察

SOM とディープラーニングの予測精度を図 3 に示す. ディープラーニングでは, 1 秒先, 10 秒先の場合でも SOM と比較し予測精度は高くなった. ディープラーニングは SOM と比較し, 風速の短期予測へ適用が可能である.

一つ目の乱流特性を考慮した結果を以下に示す.  $u$  のみを学習データとして入力した場合と,  $u$  と  $w$  を入力した場合の 2 つのパターンで 1 秒先~10 秒先を予測した時の相関係数の変化を図 4 に示す. 図 4 より, 1 秒先を予測した時は 2 つのパターンの精度にほとんど差はないが, 将来の先の予測になるほど若干精度が向上している. よって, より将来の先を予測するほど,  $w$  を学習データに加えることによる予測精度の向上に期待できる.

二つ目の乱流特性を考慮した結果を以下に示す. ここでは 10 秒先を予測した場合で検証した. 図 5 に学習データとして入力する風速の時間履歴と相関係数の関係を示す. 図 5 より, 風速の履歴を 15 秒間ずつ学習させた場合が最も相関係数が高くなった. この 15 秒間を逆数にして周波数の形に直すと 0.067 Hz である. 実際に評価対象とした風速がピークを持つ周波数帯と図 5 の予測精度との関係を検証する. 図 5 の x 軸を逆数にして周波数の形に直し, 対数表示にしたものを対象風速のスペクトル図と重ね合わせ図 6 に示す. 図 6 より, 対象風速は 0.07 Hz 付近にピークを持ち, 図 5 での予測精度が最も高くなる時間履歴と一致していた. よって, ピークを持つ周波数帯に対応する波長を含む風速の時間履歴を学習させることで, 予測精度が最も高くなることが確認できた.

以上の結果より, ディープラーニングで二つの乱流特性を考慮して最適な学ばせ方をさせることで予測精度が向上された.

### 4. おわりに

本研究では, ディープラーニングに乱流特性を考慮して学習させることで予測精度を向上させることができた. 今後は, 様々な風速データに対してディープラーニングを適用し, 入力条件による予測精度の変化を検討することにより, 新たな研究手法として乱流特性の解明を目指す.

### 参考文献

- 1) 相原研吾, 森脇亮: 自己組織化マップによる風の短期予測を用いた風車のパワーアシスト機能の効率化, 土木学会四国支部 第二十回技術研究発表会講演概要集, VII-12, pp. 309-310, 2014
- 2) 岡谷貴之, 2015: 『深層学習』, 講談社, pp. 116-123

### 謝辞

本研究は JSPS 科研費 15K06236 の援助を受けた.

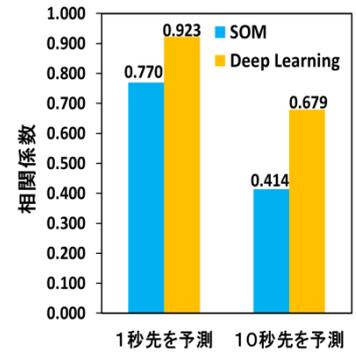


図 3 SOM とディープラーニングの予測精度

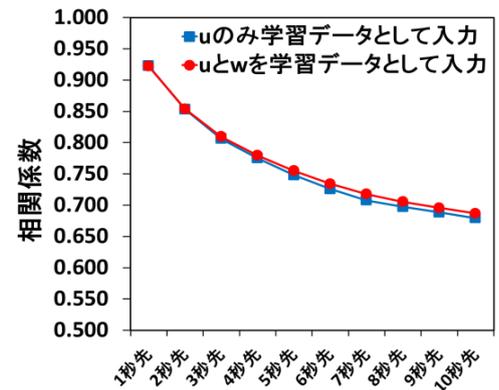


図 4 1 秒先~10 秒先を予測した場合の相関係数

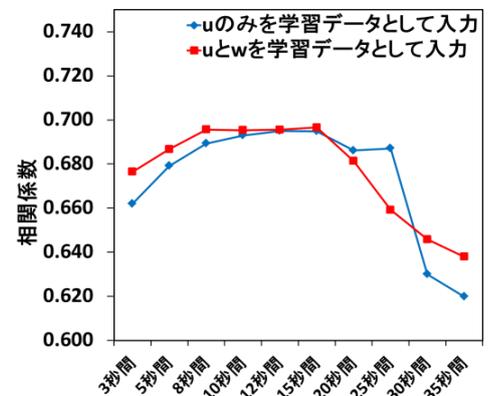


図 5 10 秒先を予測した時の入力する風速の時間履歴と相関係数の関係

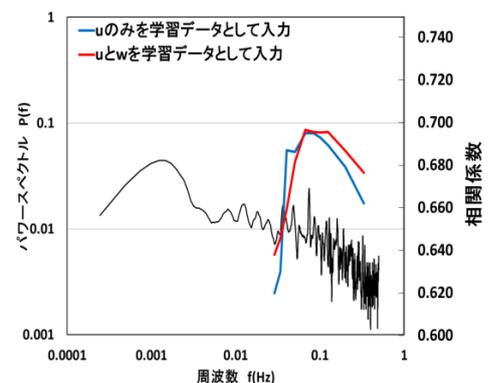


図 6 周波数構造と相関係数の関係