

ニューラルネットワークを用いた地形因子による 風況推定における観測期間の影響

徳島大学大学院 学生員 ○楠原孝明 徳島大学 正員 長尾文明
徳島大学 正員 野田 稔 徳島大学大学院 非会員 重永雄大

1. はじめに

近年、構造物は長大化、高層化の一途をたどっており、構造物に対する風の影響も大きくなっている。そのため、建設地点等の未観測地点の風況特性を知ることが重要となっている。そこで未観測地点の風況特性を推定する方法の1つとして、地形因子解析が挙げられる。さらに、ニューラルネットワークを導入することで、推定精度の良い結果が確認された¹⁾。また、地上風速と上空風速の相関係数を指標として教師データを選別することにより、効率よくニューラルネットワークの学習を行うことが確認された²⁾。

本研究では上空風と地上風の観測期間の変化に伴う推定精度の影響について考察を行った。同時に、教師データを選別する指標について考察した。

2. 解析データ及び解析対象地点

解析データは1997年から1999年までの3年間のデータ、1日2回の計2015サンプル、2002年から2006年までの5年間のデータ、1日4回の計7303サンプルが対象である。上空風速のデータは850hPa気圧面の領域客観解析データ³⁾を用い、地上風速のデータはAMeDASのデータ⁴⁾を用いる。また、地形データは国土地理院の50mメッシュの標高データを用いる。

次に、本研究で用いる地形因子は、平均標高・山度・谷度・障害度・障害距離・海岸距離の6個の地形因子に、風軸上流・下流方向を考慮した12個の地形因子である。これに、方位に無関係な観測地点の標高・風速計高さの2個の地形因子を加えた合計14個の地形因子を用いる。なお、地形因子の詳細については参考文献5)に記す。また、解析対象地点は、表-1、図-1に示す四国30ヶ所のAMeDAS観測地点である。




図-1 解析対象地点

3. 解析方法

地形因子の解析方法として、1997年から1999年の3年間を対象とするCase1、2002年から2006年の5年間を対象とするCase2、Case1とCase2を合わせた8年間を対象とするCase3の3つのケースについて解析し、観測期間の変化に伴う推定精度の影響を考察する。

さらに、それぞれのケースにおいて、教師データを選別する以下に示す4つの指標を用いて、指標ごとに解析を行う。本研究ではその指標として、上空風速と地上風速の風速比、地上風速、上空風向と地上風向との同時発現頻度、上空風速と地上風速の相関係数をとりあげる。教師データの選別方法は、設定した閾値より大きい指標のデータを教師データとしてニューラルネットワークを学習させ、設定した閾値より小さいデータを非教師データとし、非教師データを未観測の推定対象地点と扱って学習したニューラルネットワークの推定精度を検証する。各指標において解析を行う際に設定した閾値とその時の全データに対しての教師データの割合の関係を図-2に示す。どの指標においても、各閾値とその時の全データに対しての教師データの割合を各ケースで比較するとほぼ一致する。

4. 解析結果と考察

解析結果として、各ケースにおける教師データの割合と実測値と推定値の相関係数の関係を(a)全データ、(b)非教師データとして図-3に示す。

(a) 全データにおいて、教師データの割合が0.4以上では、どのケースにおいても全指標の実測値と推定値の相関が0.8を超えており、非常に良い推定精度である。また、教師データの割合が0.4以下では、Case1はどの指標も実測値と推定値の相関が低くなっている。しかし、観測期間が長くなったCase2では指標が同時発現頻度、地上風速の時の推定精度がCase1と比べ良くなっている。観測期間がさらに長いCase3では、Case1,2で相関の低かった教師データの割合が0.4以

表-1 解析対象地点の詳細

整理番号	観測地点番号	地点名	AMeDAS		整理番号	観測地点番号	地点名	AMeDAS	
			標高(m)	風速計高さ(m)				標高(m)	風速計高さ(m)
1	71066	池田	205	6.6	16	73406	宇和	208	18.6
2	71106	徳島	2	6.6	17	73442	宇和島	2	13.7
3	71231	龍生田	10	17.5	18	74136	大樹	210	33.1
4	71251	木頭	330	6.6	19	74181	高知	1	6.6
5	72086	高松	9	6.6	20	74187	御免	12	15.4
6	72111	多度津	4	16.6	21	74271	安芸	6	6.6
7	72121	滝宮	60	13.2	22	74296	梶原	415	6.6
8	72146	引田	12	6.8	23	74311	須崎	4	6.6
9	73076	今治	2	6.5	24	74361	窪川	205	6.6
10	73126	丹原	13	6.6	25	74371	室戸岬	185	6.6
11	73136	新居浜	6	14	26	74381	江川崎	60	41.8
12	73166	松山	32	34.5	27	74436	佐賀	3	6.6
13	73256	長浜	1	20.5	28	74447	宿毛	2	6.6
14	73276	久万	511	15.6	29	74456	中村	8	17.8
15	73306	大洲	17	6.6	30	74516	清水	31	6.6

下の範囲においても、より相関が高くなっている。以上より、観測期間が一番長い Case3 が最も良く推定できるといえる。

(b) 非教師データにおいては、観測期間が長くなることで、指標が同時発現頻度の場合のように精度が良くなる指標もあれば、指標が風速比の場合のように精度が悪くなる指標もあることが分かる。また、指標が同時発現頻度の場合、全ケースにおいて教師データの割合が 0.7 以上で実測値と推定値の相関が 0.8 を超えており、非常に精度良く推定できている。そこで、指標が同時発現頻度の場合の推定結果を詳しくみていく。教師データの割合が 0.3 以下では Case1 の推定精度より Case2, Case3 の推定精度の方が良く、Case3 においては実測値と推定値の相関が約 0.8 となっており、非常に良い推定精度であるといえる。しかし、教師データの割合が 0.4 から 0.6 の間では Case2, 3 の推定精度より Case1 の推定精度の方が良くなっている。

そこで、指標が同時発現頻度の時の非教師データのみを対象とした推定結果における教師データの割合と残差二乗平均の関係を図-4 に示す。すると、Case2, 3 において相関が悪かった教師データの割合が 0.4 から 0.6 の間での残差二乗平均は Case1 とほぼ等しく、全 Case の推定精度はほぼ等しくなっている。しかし、Case1 において相関が悪かった教師データの割合が 0.3 以下での残差二乗平均は Case2, 3 と比べ大きく、Case1 の推定精度が Case2, 3 より悪くなっている。

以上より、指標が同時発現頻度であると最も効率よく学習していることが分かる。さらに、参考文献 2) ではニューラルネットワークが最も効率よく学習する指標は上空風速と地上風速の相関係数であったため、用いる地形因子にともない最適な指標が変化すると考えられる。また、指標が同時発現頻度の場合、観測期間の一番長い Case3 が最も精度が良いといえる。

5. おわりに

ニューラルネットワークを用いた地形因子解析では、全データにおいては、上空風と地上風の観測期間が長いほど良い推定結果を得ることができた。また、上空風向と地上風向の同時発現頻度を指標に用いるとニューラルネットワークを最も効率よく学習させることができた。さらに、解析に用いる地形因子の変化に伴い、最適な指標も変化すると考えられるため、今後、地形因子の組み合わせを変えて解析を行う等、更なる検討が必要である。

参考文献

- 1) 野田, 長尾, 近江, 宇都宮: 上空風の情報を考慮した地上風の風況推定に関する検討, 第 19 回風工学シンポジウム論文集, pp 31-36, 2006.
- 2) 楠原, 長尾, 野田: ニューラルネットワークを用いた地形因子による風況推定の精緻化, 土木学会第 62 回年次学術講演会演説概要集 pp 330-340
- 3) 気象業務支援センター: 領域客観解析データ (CD-ROM) 1997-1999, 2002-2006
- 4) 気象業務支援センター: AMeDAS 観測データ (CD-ROM) 1997-1999, 2002-2006
- 5) 氏本, 宇都宮, 長尾, 野田: 地形因子解析による局所地形周辺の風況推定, 土木学会年次学術講演会概要集, vol.54, pp 640-641, 1999




図-2 教師データの割合に対する閾値




図-3 教師データの割合と推定値-実測値の相関係数の関係




図-4 非教師データにおける教師データの割合と残差二乗平均との関係 (指標を同時発現頻度とした場合)