

公益信託 NEXCO関係会社高速道路防災対策等に関する支援基金
受託者 三菱UFJ信託銀行株式会社 宛

研究概要書

研究課題：強風時における高速道路安全走行速度情報の事前提示に関する研究

研究代表者：京都大学大学院工学研究科 教授 白土博通
共同研究者：京都大学大学院工学研究科 (M1) 小松賢司

1. 研究の目的

強風による車両横転等の事故の防止には、風速の上昇を事前に予測し、交通規制を行うことが効果的である。そこで本研究では、道路交通の安全を確保するための風速予測システムの構築を目的に、道路沿線に設置された風速計の観測データに着目し、ニューラルネットワーク及び複数地点観測データを用いた風速予測を行った。そして、他地点観測データ使用の効果や、地点による予測精度の差異について検討した。

2. ニューラルネットワーク[1][2]

ニューラルネットワークとは、人間の脳の神経回路を模した人工知能分野のアルゴリズムであり、一般的に入力層・中間層・出力層で構成される、多数のニューロンが階層的に結合された構造をとる。ニューラルネットワークは、与えられた入力データと正解データを繰り返し学習することによってそれらの関係性を見出し、初見の観測データから予測値をダイレクトに出力することができる。本研究では、入力を処理する Encoder、出力を処理する Decoder の 2 つのニューラルネットワークから構成される RNN Encoder Decoder[3]と呼ばれるモデルを使用した。RNN Encoder Decoder の特徴は、予測値をシーケンスで出力できることである。

3. 観測地点

本研究では、西日本高速道路株式会社阪和高速道路上の 7 地点の観測地点の中から、比較的互いに近距離にあった Site1 (関空連絡橋)、Site6 (泉佐野)、Site7 (牛滝川橋) を予測対象地点として選択した。位置関係を図 1 に示す。観測期



図-1 観測地点

間は 2017/1/18 14:00 ~3/13 18:10、観測項目は 5 分毎 10 分間平均風速、データ長は、それぞれの地点につき 15600 である。そのうち 15000 をトレーニングデータ、残りの 600 をテストデータに用いた。

4. 予測の概要

予測には、中間層が 1 層、ユニット数 (ニューロン数) 12 のネットワークを Encoder と Decoder のそれぞれに用いた RNN Encoder Decoder を使用した。また、それぞれの予測対象地点に関して、表-1 に示す 4 通りずつのデータの組み合わせを用いて 30 分 (6 ステップ) 先までの風速予測を行い、それぞれの予測精度について比較した。

表-1 データの組み合わせ

予測対象地点	Site1	Site6	Site7
併用データ	なし	なし	なし
	Site6	Site1	Site1
	Site7	Site7	Site6
	Site6, Site7	Site1, Site7	Site1, Site6

5. 予測結果

それぞれのデータの組み合わせの、予測ステップ毎の予測値と観測値に関する絶対平均誤差を表-2 に示す。Site1 と Site2 においては、予測対象地点の観測データのみを予測に用いた場合の誤差値が最も小さくなった。一方、Site3 においては、予測対象地点である Site3 の観測データの他に、Site2 の観測データを入力データとして組み合わせた場合の誤差値が最も小さくなった。したがって、Site1、Site6 においては他地点の風速データを併用して学習及び予測を行っても予測精度の改善が起らなかった一方で、Site7 における風速予測では、Site6 の風速データを併用することにより、予測精度が改善したといえる。

表—2 予測ステップ毎 MAE

対象	併用	step1	step2	step3	step4	step5	step6
Site1	なし	0.201	0.352	0.450	0.525	0.588	0.647
	Site6	0.206	0.365	0.458	0.526	0.590	0.642
	Site7	0.326	0.443	0.553	0.638	0.706	0.763
	Site6,7	0.209	0.368	0.467	0.539	0.602	0.658
Site6	なし	0.234	0.283	0.320	0.346	0.369	0.393
	site1	0.245	0.292	0.325	0.350	0.371	0.388
	Site7	0.272	0.325	0.360	0.388	0.408	0.427
	site1,7	0.253	0.295	0.325	0.354	0.373	0.388
Site7	なし	0.170	0.295	0.341	0.366	0.393	0.425
	site1	0.186	0.308	0.356	0.381	0.408	0.440
	Site6	0.169	0.290	0.333	0.354	0.378	0.410
	site1,6	0.206	0.311	0.355	0.379	0.405	0.431

この予測精度の改善の要因を次のように分析した。本研究に用いた Site6 及び Site7 における全風速データに関して、式(1)で表される相互相関関数を算出した。この式は、Site6 の風速データと、タイムステップを τ 遅らせた Site7 の風速データの相関係数を意味する。

$$\rho_{x,y}(\tau) = \frac{\frac{1}{m} \sum_t (x_t - \bar{x})(y_{t+\tau} - \bar{y})}{\sqrt{\frac{1}{m} \sum_t (x_t - \bar{x})^2} \sqrt{\frac{1}{m} \sum_t (y_{t+\tau} - \bar{y})^2}} \quad \#(1)\#$$


x_t, y_t : Site6, Site7 における時刻 t の観測値

\bar{x}, \bar{y} : 観測値の平均 m : データ数 τ : タイムラグ

横軸 τ でプロットした相互相関関数を図—2 に示す。図—2 より、相互相関関数のピークが $\tau = -1, -2$ に存在し、また、全

体的に τ が負の領域で、正側の領域に比べて値が高くなった。このことから、Site7 での風速変動が Site6 に比べて遅れる傾向があると言える。したがって Site7 における風速予測で、Site6 の風速データを併用することによって予測精度が改善したのは先に風速の変動が起こる傾向がある Site6 の風速データを与えられることにより、Site7 における予測の補助になったためだと考えられる。

また、それぞれの地点で最も誤差値が小さかったデー



図—2 相互相関関数

タの組み合わせパターンの、予測値と観測値に関する予測ステップ毎の相関係数を表—3 に示す。Site1 の予測精度が最も高く、続いて Site7、Site6 の順となった。

表—3 地点別相関係数

対象	併用	step1	step2	step3	step4	step5	step6
Site1	なし	0.993	0.976	0.957	0.937	0.917	0.899
Site6	なし	0.847	0.757	0.695	0.636	0.585	0.541
Site7	site6	0.979	0.936	0.914	0.902	0.889	0.870

海に囲まれた橋梁上の観測地点である Site1 で予測精度が高く、平野部と山地の境目に位置する Site6、Site7 で予測精度が低くなったことから、地形による風況変動の違いが予測精度に影響しているのではないかと考え、風速及び風向の変動に関する指標を式(2)~(4)で定義し、本研究で用いた風速データに対して計算し表—4 に示した。

$$\overline{\Delta x} = \frac{1}{m-1} \sum_{k=1}^{m-1} |x_{k+1} - x_k| \quad \#(2)$$

$$P_{ws} = \frac{\overline{\Delta x}}{\bar{x}} \times 100 \quad \#(3)$$

$$P_{wd} = \frac{\text{風向変化の回数(16方位)}}{m-1} \times 100 \quad \#(4)$$

x_k : 観測値, \bar{x} : 平均値, m : データ数

表—4 風況変動

	Site1	Site6	Site7
平均風速変動 $\overline{\Delta x}$ [m/s]	0.31	0.38	0.25
風速変動割合 P_{ws} [%]	6.7	24.9	10.4
風向変動割合 P_{wd} [%]	21.4	45.5	31.9

風速変動割合、風向変動割合の値から、風況変動の大きさは、Site1 が最も小さく、つづいて Site7、Site6 の順となった。このことから、地形や周辺の障害物等の影響で風速及び風向の変動の大きい地点では、予測が難しく、予測精度が低くなると考えられる。

6. 結論および課題

- 地形が複雑で、風速及び風向の変動が大きな地点においては予測精度が低下すると考えられる。
- 風速の変動が先に起こる傾向がある地点の風速データを併用すると予測精度が向上すると考えられる。
- ✓ 他の地点・期間に対する検討
- ✓ 風速に影響を与えうる気象データの併用
- ✓ ARIMA モデル等の他の手法との精度比較

<参考文献>

[1] 巢籠悠輔: 詳解ディープラーニング TensorFlow・Keras による時系列データ処理, マイナビ出版, 2017 [2] 斎藤康毅: ゼロから作る Deep Learning Python で学ぶディープラーニングの理論と実装, オライリー・ジャパン, 2016 [3] Kyunghyun Cho, 他: Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, 2014