

ニューラルネットワークを用いた複数ステップ先風速予測

京都大学工学部 学生員 ○小松 賢司
京都大学大学院工学研究科 正会員 白土 博通
京都大学大学院工学研究科 学生員 張 騰月

1. 概要

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、AIを利用した風速の短期的将来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を用いた風速予測を行った。そして、地点による予測精度の違いや、その原因について検討した。また、予測精度の程度を確かめるために ARIMA モデル（自己回帰和分移動平均モデル）を使用した場合と比較した。

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。

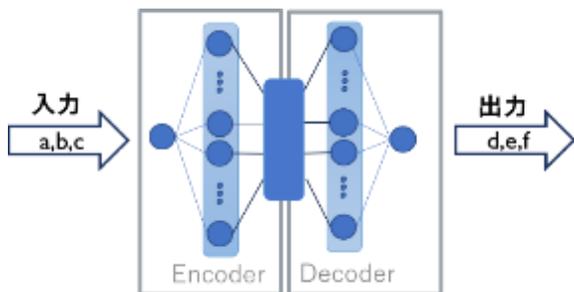


Fig1 RNN Encoder Decoder

3. 観測地点及び予測の概要

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 Fig2 に示す。



Fig2 観測地点

観測期間は 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。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、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。

4. 予測結果

それぞれの地点における、予測値と観測値に関する予測ステップ毎の相関係数を Table1 に示す。

Table1 地点別予測ステップ毎相関係数

	step1	step2	step3	step4	step5	step6
Site1	0.993	0.976	0.957	0.937	0.917	0.899
Site6	0.847	0.757	0.695	0.636	0.585	0.541
Site7	0.978	0.932	0.908	0.895	0.880	0.859

キーワード AI, 風速予測 ニューラルネットワーク ARIMA モデル

Kenshi KOMATSU, Tengyue ZHANG, Hiromichi SHIRATO

〒615-8540 京都市西京区京都大学桂桂キャンパス C1 棟 TEL 075-383-3170 MAIL komatsu.kenshi.32m@st.kyoto-u.ac.jp

予測ステップが大きくなるにつれ、相関係数の値が次第に小さくなっている。また、Site1 の予測精度が最も高く、続いて Site7、Site6 の順となり、特に Site6 における予測精度が低くなった。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(1)~(3)で定義し、本研究で用いた風速データに対して計算し Table2 に示した。

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

$$P_{ws} = \frac{\overline{\Delta x}}{\bar{x}} \times 100 \quad (2)$$

$$P_{wd} = \frac{\text{風向変化の回数(16方位)}}{m-1} \times 100 \quad (3)$$

x_k : 観測値, \bar{x} : 平均値, m : データ数

Table2 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。Site6 及び Site7 はどちらも平野と山間部の境目に位置する地点であるが、風況変動に比較的大きな差があった。これは Site6 の風速計の周囲に樹木や建造物が存在していることが原因であると考えられる。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。

5. ARIMA モデルとの比較

RNN Encoder Decoder の予測精度の程度について調べるために、同じ期間の風速データに関して、筆者らが用いてきた従来の手法である ARIMA モデルを用いて予測を行った際の予測精度と、RNN Encoder Decoder を用いた場合の予測精度を比較した。それぞれの手法による予測値と観測値の相関係数を Table3 に、予測値と観測値の絶対平均誤差 MAE を Table4 に示す。

Table3 及び Table4 より、RNN Encoder Decoder によ

る予測の予測精度と、ARIMA モデルによる予測の予測精度には大きな差異はないことが分かる。したがって、これら2つの手法では、ほぼ同程度の予測ができていと考えられる。しかしながら、RNN Encoder Decoder の学習は計算量が多く、ARIMA モデルに比べて時間を要するという点で不利である。

Table3 予測精度比較 (相関係数)

CC		Step1	Step2	Step3	Step4	Step5	Step6
Site1	RNN	0.993	0.976	0.957	0.937	0.917	0.899
	ARIMA	0.993	0.974	0.953	0.931	0.908	0.885
Site6	RNN	0.847	0.757	0.695	0.636	0.585	0.541
	ARIMA	0.852	0.76	0.7	0.643	0.594	0.548
Site7	RNN	0.978	0.932	0.908	0.895	0.88	0.859
	ARIMA	0.979	0.93	0.905	0.891	0.873	0.852

Table4 予測精度比較 (MAE)

MAE		Step1	Step2	Step3	Step4	Step5	Step6
Site1	RNN	0.201	0.352	0.45	0.525	0.588	0.647
	ARIMA	0.193	0.357	0.466	0.542	0.618	0.679
Site6	RNN	0.234	0.283	0.32	0.346	0.369	0.393
	ARIMA	0.228	0.28	0.311	0.335	0.355	0.377
Site7	RNN	0.17	0.295	0.341	0.366	0.393	0.425
	ARIMA	0.168	0.299	0.349	0.376	0.406	0.438

6. 結論

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。

RNN Encoder Decoder を用いた予測と、ARIMA モデルによる予測の予測精度には大きな差異はなく、同程度の予測ができていと考えられる。

7. 今後の課題

- 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
- 実用面を考慮したシステムの構築

<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