

2020 年度 風工学研究拠点 共同研究成果報告書

研究分野：室内環境分野

研究期間：2020 年度

課題番号：20203005

研究課題名（和文）：自然換気設計における AI の有用性に関する研究

研究課題名（英文）：Study on the usefulness of AI in natural ventilation design

研究代表者：遠藤智行

交付決定額（当該年度）： 200,000 円

1. 研究の目的

地球温暖化等の環境問題への対応として、建築物の運用段階における排出量削減が急務となっており、建築設備の効率的な運用が重要視されている。運用段階におけるエネルギー消費量の低減手法として、空気環境分野においては自然換気が注目されている。特に、建物壁面に作用する風圧力により屋内の換気を促す風力換気は、事前に実験やシミュレーションにより建物壁面における風圧力を予測し、それを加味しなければ効果的な運用を行うことができない。建物壁面における風圧力の予測手法としては風洞実験や CFD（数値流体力学）ソフトウェアなどが実務上では一般的に用いられている。空気の流れは解析的に推定することは困難であるため、実際の空気環境を再現する風洞実験では高い精度が担保される。その代償として、専用の風洞実験設備が必要となるほか、専用の実験模型が必要であり、準備を含め実験には膨大な時間と労力を要する。対して、近年様々な場で活躍を見せる深層学習（Deep Learning）等の機械学習手法により構築された予測モデルは、予測に要するコストや労力が上記の手法と比較し、軽減可能であると予想される。本研究では、AI を用いて建物壁面に作用する風圧係数を予測し、風洞実験結果と比較検討することで、AI による風圧係数予測の可能性について検討する。また、自然換気の換気駆動力は気象情報に大きく左右されるため、自然換気設計を行う上では、気温、風向、風速などの気象情報を考慮する必要がある。そのため、有効な自然換気設計を考える上で、気象情報は非常に重要な要素である。現在、気象情報の入手方法としては気象庁で公開されているアメダスなどが代表的であるが、アメダスで公開されている地点は非常に限定的である。そのため、設計地点の気象情報があるとは限らず、局所的な気象情報はスーパーコンピュータの数値計算による予測を行う等の対応が必要である。しかし、上記のような手法による予測は膨大な時間とコストを要するため、設計の度に実行することは現実的ではない。環境設備の設計や省エネルギー予測などにシミュレーションソフトを用いる場合、外気の気象データとして先に示したアメダス標準年気象データ等を用いることが考えられるが、これらのデータは対象地域が限定的であり、設計地点に適した気象データとならない可能性がある。これらに対応するツールの作成を目的として、本研究では機械学習の一種であるニューラルネットワーク（以下：NN）を用いて、アメダス観測地点の気象データから、その他の地点の気象予測を行う手法について検討する。

2. 研究の方法

NN による風圧係数分布予測において学習データ取得を目的とした風洞実験を実施した。対象とする建物は、単純形状建物（幅：奥行き：高さ＝2：2：1、以降 221 モデル）を基準として、昨年度は高さを 2 倍、3 倍、4 倍したが、今年度は幅を 2 倍、3 倍、4 倍した 3 種類の形状の建物とした。既に取得している 1 列、本年度取得した 2~4 列、計 4 列のうち、1 列と 3 列の風圧係数分布を NN に学習させる。学習が完了したのち、学習済み NN モデルにより 2 列、4 列の風圧係数分布を予測する。予測結果を測定値と比較することで NN による予測精度の検討を行う。今回の測定により高さ方向に加え横方向の測定データが取得できたため、今後は奥行き方向を加えた三次元での風圧係数分布予測を行うことが可能になると考える。NN による気象予測は気象庁のホームページで公開されている日本全国の気象データを学習させることで、未学習である局所的な気象条件を予測させる。これによってシステムシミュレーションを用いた予測において、予め用意されている気象情報以外の地点における気象情報の推測が可能になり、より建設予定地に近い状況での予測が可能になると考えられる。

3. 研究成果

3.1. 単純形状建物壁面における風圧係数の予測

3.1.1. 研究概要

本研究では NN による単純形状建物壁面における風圧係数分布の予測を行うにあたり、ニューラルネットワークに学習させるデータ取得を目的として風洞実験により 4 種の建物形状における壁面の風圧係数分布を取得した。今回は東京工芸大学厚木キャンパス所有のエッフェル型境界層風洞（風洞段目 W1200mm×H1000mm）にて測定を行った。221 モデルをもとにした単純形状の建物を対象に、その幅の変化に応じた風圧係数の予測を行い、二次元的な形状変化に伴う分布傾向変化の把握を目指す。建物幅が変化した場合の風圧係数分布傾向の変化を把握させるため、図 1 に示す 221 モデルをもとに、その幅を 2 倍、3 倍、4 倍とした 2 列、3 列、4 列モデルの 9 風向分(0°~180°、22.5°間隔)の風圧係数分布を風洞実験により取得した。

表 1 風洞設備概要及び実験条件

風洞装置概要	
風洞形式	エッフェル型境界層風洞
測定洞全長	22,400mm
測定洞断面	幅：1,200mm、高さ：1,000mm
実験条件	
平均風速べき指数： α	0.25
風洞風速(軒高レベル)	7[m/s]
実験建物形状	2 列、3 列、4 列
実験風向	9 風向(0°~180°、22.5°間隔) 風圧測定面が風洞気流に正対する角度を 0°とする




図 1 1 列～4 列モデル概要図

3.1.2. 入出力項目

表 2 に予測モデルの入出力項目を示す。①～⑥の項目については、①～②のうち長辺方向の数値により除して無次元化の処理を行う。無次元化を行うことで数値を 0～1 の間に収まるため、学習をしていない形状でも実質的に学習の範囲内となり、未知の形状の予測にも対応できる可能性がある。

表 2 学習・予測時の入出力項目

学習・予測時における入出力項目		
入力	① 壁面水平方向長さ	予測対象壁面の水平・垂直方向全長
	② 壁面垂直方向長さ	
	③ 壁面水平方向距離 (左端起点)	風圧測定孔 (=予測点) の壁面上の位置を示す
	④ 壁面水平方向距離 (右端起点)	
	⑤ 壁面垂直方向距離 (上端起点)	
	⑥ 壁面垂直方向距離 (下端起点)	
	⑦ 風向角	風洞気流が風圧測定面に正対する時を風向角 0°とする
出力	⑧ 風圧係数値	③～⑥で指定した点における風圧係数値

3.1.3. ネットワークの構築

ネットワークの最適化を行い、複数のネットワークを作成したのち、訓練誤差が最も小さかったネットワークを予測モデルとして選定した。表 3 に本研究で使用したネットワーク構造を示す。

表 3 予測ニューラルネットワーク構成

ネットワーク構成	
入力層ノード数	7
中間層 1 ノード数	39
中間層 2 ノード数	50
出力層ノード数	1
中間層 1 の活性化関数	Tanh
中間層 2 の活性化関数	Swish
最適化アルゴリズム	Adam
最大エポック数	500
バッチサイズ	1

3.1.4. 結果

風圧係数分布の風洞実験値及び NN による予測値と相関関数値 R を以下に示す。

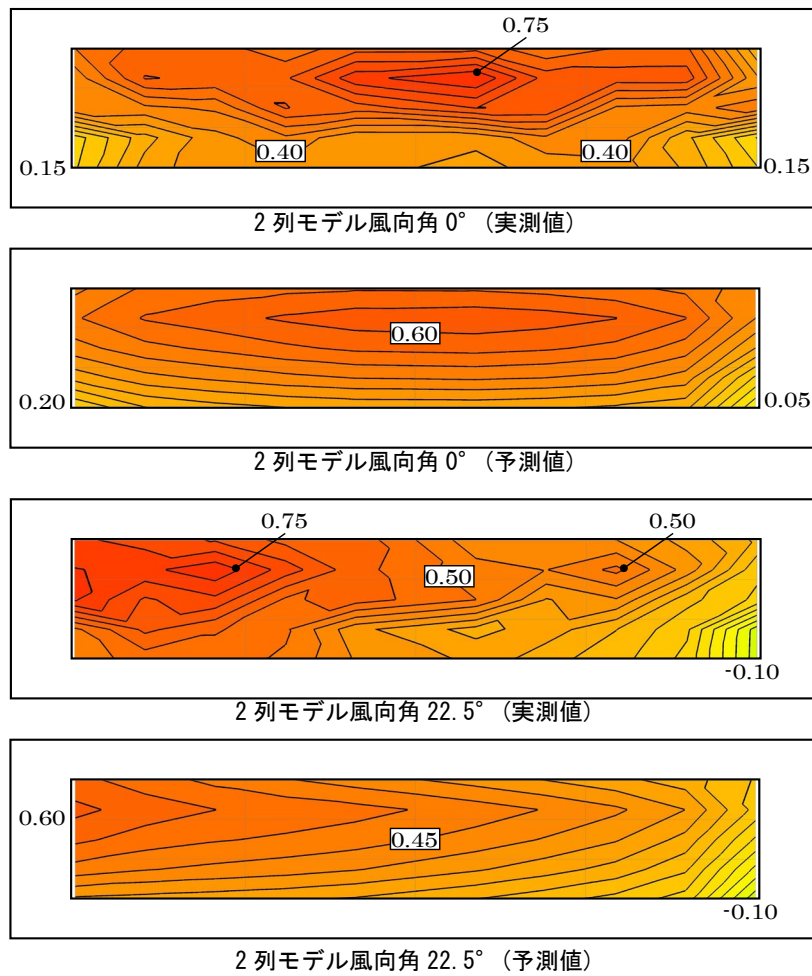


図 2 2 列モデル平均風圧係数分布図の比較 (風向角 0°、22.5°)




図 3 2 列モデルの実測値と予測値の相関 (風向角 0°、22.5°)





図4 2列モデルの実測値と予測値の相関(風向角 45°、67.5°)





図5 2列モデルの実測値と予測値の相関(風向角 90°、112.5°)




図6 2列モデルの実測値と予測値の相関(風向角 135°、157.5°)







図7 2列モデルの実測値と予測値の相関(風向角 180°)




4 列モデル風向角 0° (実測値)



4 列モデル風向角 0° (予測値)



4 列モデル風向角 22.5° (実測値)



4 列モデル風向角 22.5° (予測値)

図 8 4 列モデル平均風圧係数分布図の比較 (風向角 0°、22.5°)




図 9 4 列モデルの実測値と予測値の相関 (風向角 0°、22.5°)

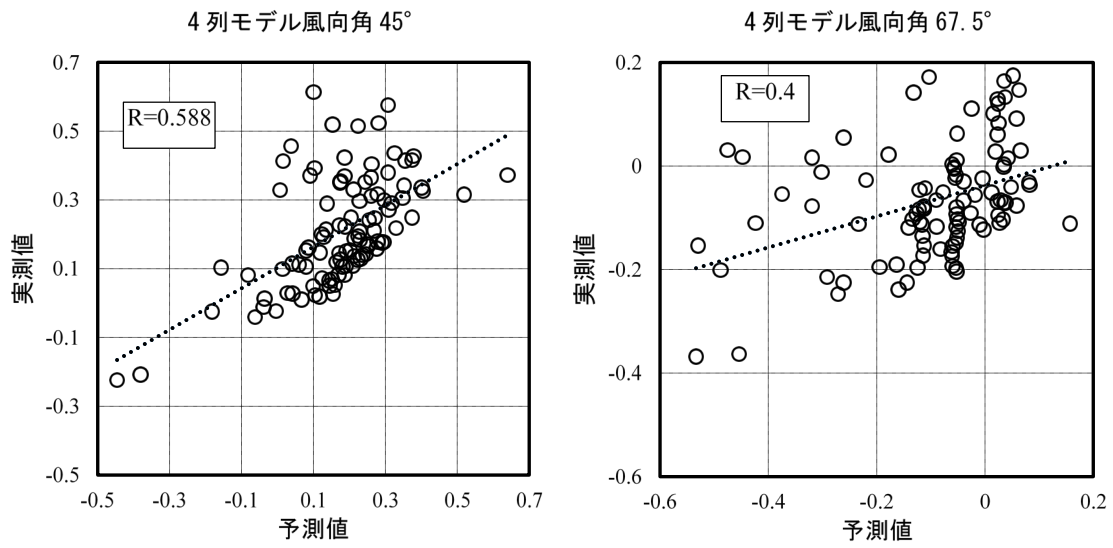


図 10 4列モデルの実測値と予測値の相関(風向角 45°、67.5°)




図 11 4列モデルの実測値と予測値の相関(風向角 90°、112.5°)




図 12 4列モデルの実測値と予測値の相関(風向角 135°、157.5°)




図 13 4列モデルの実測値と予測値の相関(風向角 180°)

3.1.5. 考察

風圧係数分布図による予測精度の評価

図 2～図 13 より、2 列・4 列モデルともに風洞実験値に近い分布となっているが、各風向の最大値、最小値に着目すると、風圧係数値の絶対値が大きい方へ過大に評価される傾向が確認できる。また、その誤差はおよそ 0.2 程度であり、2 層・4 層の予測時における誤差と比較して大きい。このように予測誤差が大きくなった要因として、学習に用いた風洞実験値がノイズを含んでいることが影響していると考えられる。風圧測定模型の都合により、2 列～4 列モデルの測定時も、1 列ずつ局所的な測定を行い、その結果を結合することで全面的分布とみなしている。今回取得したデータは A/D 変換ボードにおけるノイズが混在してしまっているが、横方向に連結した際に、このノイズの影響が大きくなってしまい、実験値から作成した風圧係数分布図と予測値から作成した風圧係数分布図に相違が生まれたと考えられる。

相関係数による予測精度の評価

表 4 より、2 列の全風向平均相関係数値が 0.86、同様に 4 列の数値が 0.71 であり、概ね良好な精度で予測ができているとわかる。2 列の数値を風向別に見ると、2 層・4 層の結果と同様に、風向角 157.5°と 180°を除く他の風向では 0.8 を下回るものがなく、非常に精度が高いことが確認できる。対して、4 列の数値を風向別に見ると、風向角 45°と 67.5°の数値は他風向に比べ著しく低い。風向角 45°の風圧係数分布図では、風洞実験結果には風圧が最も高くなる淀み点が 4 か所に見られるのに対し、NN による予測結果では、このノイズが排除され等高線が平滑化されていた。他の形状の風向角 45°の結果と比較した際、NN による予測結果の方が近い分布傾向が表れていることから、4 列の風向角 45°と 67.5°の予測精度は実際には低くはない可能性がある。また、他の風向では相関係数値は 0.7 を下回るものがなく、一部風向では 0.9 より大きいものも確認できるため、全体的に概ね良好な精度であると考えられる。

建物形状による異なる分布傾向の抽出

2 列・4 列モデルについても学習データである 1 列・3 列モデルから、その特徴を良好な精度で抽出し、学習することが可能であると確認できた。また、学習データに含まれるノイズを排除し、等高線を平滑化するような作用が確認できた。

表 4 実測値と予測値の相関係数値 R

		風向角									形状別
		0°	22.5°	45°	67.5°	90°	112.5°	135°	157.5°	180°	平均値
予測	2 層	0.86	0.94	0.96	0.84	0.96	0.93	0.92	0.62	0.66	0.86
形状	4 層	0.71	0.71	0.59	0.40	0.84	0.93	0.91	0.92	0.76	0.71

3.2. ニューラルネットワークによる気象予測の基礎的検討

3.2.1. 研究概要

学習地点は47都道府県の各主要都市一か所(表5)を抜粋し、2000～2019年、計20年分の5～7月における気温を学習させた。その後、神奈川県横浜市金沢区に位置する関東学院大学5号館建築・環境棟の2019年、6月の気温を予測した。なお、予測地点に位置する神奈川県、面積の広い北海道、気象条件の特異な沖縄県は学習地点を複数とした。学習項目は前述の通り予測する地点の位置情報と時刻情報を入力しそれに対応する回答として入力した。時刻情報は、年、月、日付、時刻とし、位置情報は緯度、経度、標高とした。また、学習予測間隔は一時間ごととした。学習時は上記の年、月、日付、時刻、緯度、経度、標高とそれに対応する気温の計8項目を入力した。

表5 47都道府県学習地点

各都道府県学習地点				
〈北海道〉14地点	〈東北〉6地点	辻堂	名古屋	〈四国〉4地点
稚内	青森	小田原	津	徳島
旭川	盛岡	三浦	〈近畿〉6地点	高松
留萌	仙台	海老名	彦根	松山
札幌	秋田	東京	京都	高知
岩見沢	山形	千葉	大阪	〈九州・沖縄〉9地点
小樽	福島	さいたま	神戸	福岡
網走	〈北関東〉5地点	〈北陸〉4地点	奈良	大分
根室	甲府	新潟	和歌山	長崎
釧路	水戸	富山	〈中国〉5地点	佐賀
帯広	宇都宮	金沢	鳥取	熊本
苫小牧	前橋	福井	松江	宮崎
浦河	長野	〈東海〉4地点	岡山	鹿児島
函館	〈南関東〉8地点	静岡	広島	名護
江刺	横浜	岐阜	山口	那覇
				合計65地点

入出力項目・使用ネットワーク

学習時は表6の①～⑦の年、月、日付、時刻、緯度、経度、高さの7項目とそれに対応する気温を学習させた。予測時は①～⑦の項目を入力することで気温が予測値として出力される。使用したネットワーク構成は自動探索を行った結果、最も精度が高いものを使用した。本研究で用いたネットワーク構造を表6に示す。

表6 入出力項目・使用ネットワーク構造

学習・予測時における入出力項目		ネットワーク構造			
入力	①年	学習(予測)点の年月日時刻情報 ※時刻は一時間間隔とする	入力層ノード数	7	
	②月		中間層数	10	
	③日		出力層ノード数	1	
	④時刻		中間層の活性化関数	Swish	
	⑤緯度		学習サイクル数	500	
	⑥経度		学習(予測)点の位置情報	バッチサイズ	100
	⑦標高		①～⑦に対する気温		
出力	⑧気温	※AMeDASから入手する気温は対象時刻の前一分間の平均気温である			

3.2.2. 結果・考察

以下に気温の実測値と予測値の比較を示す。




図 14 気温実測値・予測値比較 (一ヶ月)

図 14 より、一か月単位の結果は概ね予測できており、日にちごとの最高気温、最低気温の変化も捉え、一日の気温の変化の流れも予測できている。そして、8 日から 11 日にかけて気温が下がり、11 日から再度気温が上昇するという変則的な変化を予測できていることがわかる。




図 15 気温実測値・予測値比較 (6/1~7)




図 16 気温実測値・予測値比較 (6/15~21)

しかしながら、図 15 の 6 日に注目すると予測値と実測値は大きく異なる。原因として最高気温が 30°C を超えており、例年の 6 月の平均気温を大きく超える特殊な気象条件だったことが考えられる。同様に、図 16 の 15 日も精度の高い予測ができていない。当時の気象状況を確認すると日本全国で大雨や強風の荒れた天気であったため、日中になっても気温が上がらず平年通りの気温になっていなかった。その結果、予測値と実測値が大きく異なると考えられる。そのため、学習データに含まれていない特異な気象条件の予測は現状では困難であると考えられる。




図 17 時刻別絶対誤差率

時刻別絶対誤差率を箱ひげ図 17 に示した。図中の×印はその時刻の絶対誤差率の平均値を示しており、折れ線グラフは平均値をつないだものである。図 17 から、絶対誤差率の平均に関しては概ね 5%~10%に推移しており、決まった時刻において飛び抜けて高いということはない。また、夜間から未明の気温が低い時刻帯は平均値が一桁のため、予測値の精度が日中と比べて高いと考えられる。しかしながら、最大値に注目すると、気温が高くなる正午から夕方までの時間帯において高くなっている。また、同時刻帯では外れ値が多くなっていることがわかる。

3.2.3. まとめ

本研究では、NN を用い都道府県の各主要都市から抜粋した箇所の気温を学習させ、関東学院大学 5 号館建築・環境棟の予測を行い、実測値と比較することで予測値の精度と有用性について検証した。予測結果は実測値と誤差が 1℃を下回る日付もあり、概ね良好であったと考えられる。予測値が毎日同じということもなく、気温が全体的に低い日は予測値も全体的に低くなるなど、日付ごとの変化を読み取ることが出来た日も存在した。しかしながら、予測が困難である日も存在した。特に、気象条件が平年とは大幅に異なる場合の予測や、24 時間の気温の変化がまったくないという特殊な状況での予測に関しては、大幅な改善の余地がみられた。

4. 主な発表論文等

(研究代表者、研究分担者には下線)

[学会発表] (計 1 件)

1. 菊地 拓、遠藤 智行：有効な自然換気設計を目的としたニューラルネットワークによる気象予測の基礎的検討、第 54 回空気調和・冷凍連合講演会

5. 研究組織

(1) 研究代表者

遠藤 智行 関東学院大学・建築・環境学部 教授

(2) 研究分担者

1. 水谷 国男 (東京工芸大学・工学部・教授)
2. 山本 佳嗣 (東京工芸大学・工学部・准教授)
3. 新井 涼太 (関東学院大学大学院・工学研究科・修士 2 年)
4. 山本 耕平 (関東学院大学大学院・工学研究科・修士 2 年)


6. 要約(Abstract、英文)

Research Theme : Study on the usefulness of AI in natural ventilation design

Representative Researcher (Affiliation) : ENDO Tomoyuki (Kanto Gakuin University)

【Wind pressure coefficient distribution prediction by AI】

It is difficult to estimate the air flow analytically. In a wind tunnel experiment that reproduces the actual air environment, high accuracy is guaranteed, but it takes a huge amount of time and effort to carry out the experiment. On the other hand, a prediction model by a machine learning method such as deep learning is expected to be able to reduce the cost and labor required for prediction as compared with the above method. In this study, the wind pressure coefficient distribution of 9 wind directions (0 ° to 180 °, 22.5 ° intervals) is obtained in the 2-row, 3-row, and 4-row models in which the width of the basic building is doubled, tripled, and quadrupled by neural network (NN).




2 row model 0 degree (Left: Wind tunnel experiment, Right: NN)

Looking at the prediction results, it was confirmed that the noise of the experimental values was eliminated and the results were smoothed. In this study, noise was mixed in a part of the training data, so there was a difference between the experimental result and the predicted value in a part. However, since it showed high prediction accuracy under other conditions, it is considered possible to make predictions with good accuracy if the target is limited to simple shapes.

【Meteorological forecast by NN】

Meteorological information is a very important factor in considering an effective natural ventilation design. When using simulation software for designing environmental equipment and predicting energy conservation, it is conceivable to use AMeDAS standard year meteorological data as the meteorological data for the outside air. However, these data have a limited number of observation points and may not always be suitable meteorological data for the design point. For the purpose of creating tools corresponding to these, in this research, we examined a method of predicting the weather at other points from the meteorological data at the AMeDAS observation point using NN.



The monthly results were generally good. We were also able to confirm the prediction accuracy of the 24-hour temperature change, minimum temperature, and maximum temperature. The accuracy when the weather conditions are different from normal or when there is a large temperature rise is an issue for the future.