

AI技術を用いた建物周辺の風速・風圧分布予測に関する研究

中村 良平*¹・吉川 優*²

Keywords : AI, 3D-CNN, CFD, wind velocity, wind pressure

AI, 3D-CNN, CFD, 風速, 風圧

1. はじめに

一般に高層ビル等の大規模建築物の設計時には、強風・暴風に対する耐風設計、およびビル風に対する風環境計画のために風洞実験または数値流体計算(Computational Fluid Dynamics, CFD)が行われることが多い。実務におけるCFDでは高速なRANS(Reynolds Averaged Navier-Stokes)が用いられることが一般的であるが、近年では計算機の高速化、研究成果の充実に伴ってLES(Large Eddy Simulation)により風速・風圧の変動場を解くことも可能になってきた。しかし、風洞実験やCFD(特にLES)は実施に相応の時間とコストを要するため、実施できるプロジェクトや回数はおのずと限られる。

一方、近年では機械学習の一種で画像認識や画像生成に有効な畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)を活用した建物

周辺の風速・風圧予測に関する研究事例が報告されている^{1),2),3)}。著者も市街地を対象とした建物周辺の風速および風圧分布の予測に関する検討を行っており、風洞実験やCFDをしのぐ高速性および簡易性を確認している^{4),5)}。本稿では、市街地における建物周辺の風速・風圧分布予測に3次元CNN(3D-CNN)を適用した場合の予測精度について検討した結果を報告する。

2. 3D-CNNを用いた風速・風圧分布予測

2.1 概要

生物の神経回路網を模倣した人工ニューラルネットワークに関する研究は1940年代に開始されたといわれている⁶⁾。現在は学習モデルの高度化とGPU等による高速演算、ビッグデータ利用に基づく深層学習(Deep Learning)が主流となっている。深層学習には目的に応じていくつかの方法論が存在するが、本研究では画像



図-1 AI技術を用いた風速・風圧分布予測の概略
Fig.1 Outline of prediction of wind velocity and pressure distribution using AI

* 1 技術センター 先進技術開発部 AI連携技術開発室

* 2 技術センター 都市基盤技術研究部 空間研究室

の認識や生成に有効とされる CNN を 3 次元に拡張した 3D-CNN を用いる。3D-CNN を用いた風速・風圧分布予測の概略を図-1 に示す。建物形状データを入力するだけの簡易さと、数秒で予測結果を出力する高速性が最大の特徴である。このように従来技術に代替して入出力を再現する学習モデルはサロゲートモデル（代替モデル、代理モデル）と呼ばれる。

2.2 学習モデル

本研究で用いる 3D-CNN の学習モデルの構成を表-1 に示す。Output shape の数値は順にその層の出力データの平面 X,Y 方向、鉛直 Z 方向の解像度、カーネル数を示す。モデルは畳み込み層と転置畳み込み層からなる 1～16 層と、入力の建物形状データ（図-2）をボクセル毎に乗算する出力層で構成される。本モデルは全結合層を用いないことから全層畳み込みネットワーク（FCN）とも呼ばれる構成である。1～15 の各層にはバッチ正規化および ReLU 関数、16 層には Sigmoid 関数を採用し、損失関数には平均二乗誤差、最適化アルゴリズムには Adam を用いた。なお、同表に示す 3D-CNN モデルの構成は一例であり、3D U-Net⁷⁾など他のボクセルデータ出力型の学習モデルを用いても良いと考えられる。

2.3 データ構成

入力データは建物形状および風向の水平 X 成分・Y 成分をそれぞれ表す計 3 種類のボクセルデータである（図-2）。建物形状は建物部分を 0（黒）、非建物部分を 1（白）で表した 2 値データ、風向の X 成分および Y 成分は、各成分の値を 0～1 に基準化し、それぞれ全画素一様としたデータである。

入力データの正解値に相当する教師データは建物周囲の風速分布および風圧分布を表す計 4 種類のボクセルデータである（図-3）。それぞれ建物部分を 0、非建物部分を高さ 450m（地表面粗度区分Ⅲの Z_G に相当）の風速および速度圧により 0～1 に基準化した風速分布および風圧分布としたデータである。なお、教師データは表-2 に示す条件で計算した CFD の結果から生成した。

2.4 学習方法

建物の数や形状、位置のパターンにより変化する建物周辺の複雑な風速・風圧分布を予測するため、本研究では様々な市街地モデルにおける風速・風圧分布を学習に用いた。主として高層建物を含む計 17 種類の市街地モデルにおける CFD 結果のうち、15 種類を訓練用、2 種類をテスト用に用いた。風向数は訓練用、テスト用ともに 22.5° 刻みの計 16 風向である。

表-1 3D-CNN モデルの構成

Table 1 Architecture of the 3D-CNN model

Layer No.*1	Layer Type	Kernel size*2	Stride*2	Output shape (X, Y, Z, Channel)
Input	-	-	-	(96, 96, 64, 3)
1	畳み込み	5	2	(48, 48, 32, 32)
2	畳み込み	3	1	(48, 48, 32, 32)
3	畳み込み	5	2	(24, 24, 16, 128)
4	畳み込み	3	1	(24, 24, 16, 128)
5	畳み込み	5	2	(12, 12, 8, 512)
6	畳み込み	3	1	(12, 12, 8, 512)
7	畳み込み	5	2	(6, 6, 4, 1024)
8	畳み込み	3	1	(6, 6, 4, 1024)
9	転置畳み込み	4	1/2	(12, 12, 8, 512)
10	畳み込み	3	1	(12, 12, 8, 512)
11	転置畳み込み	4	1/2	(24, 24, 16, 128)
12	畳み込み	3	1	(24, 24, 16, 128)
13	転置畳み込み	4	1/2	(48, 48, 32, 32)
14	畳み込み	3	1	(48, 48, 32, 32)
15	転置畳み込み	4	1/2	(96, 96, 64, 32)
16	畳み込み	3	1	(96, 96, 64, 4)
Output	乗算*3	-	-	(96, 96, 64, 4)

*1 No.1～15 はバッチ正規化, ReLU 関数, No.16 は sigmoid 関数, *2 3 次元




図-2 入力データ（3次元のうち一平面を示す）

Fig.2 Input data (A plane in 3D data)

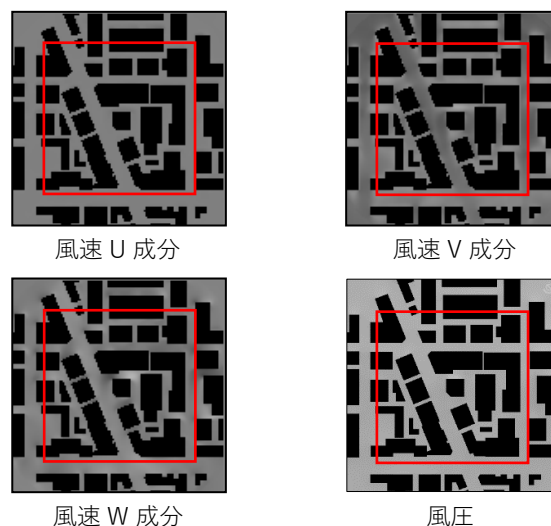


図-3 教師データ（3次元のうち一平面を示す）

Fig.3 Training data (A plane in 3D data)

表-2 教師データに用いた CFD の概要

Table 2 Outline of CFD used as training data

乱流モデル	改良 k-ε (LK モデル)
流入風	地表面粗度区分Ⅲ
地面境界	粗面対数則
建物表面境界	滑面対数則
上空・側面境界	Free Slip
風向数	16 風向 / 市街地

15 種類の市街地モデルの CFD 結果をそのまま訓練に用いてはサンプル不足であるため、市街地モデル全体から任意の位置でデータを切り出す操作を行う。これにより、予測可能な街区の範囲は小さくなるものの、訓練データを大量に生成可能となる。具体的には、各市街地モデルからおおよそ $X=480m \times Y=480m \times Z=240m$ の広さに相当する $128px \times 128px \times 64px$ のボクセルデータを作成し、そこから $96px \times 96px \times 64px$ (図-2, 図-3 の赤枠) のボクセルデータを訓練のイテレーションごとにランダムな X-Y 平面位置で切り出す。切り出し位置は入力データおよび教師データの各データで同じとする。また、鉛直 Z 軸周りにおける 90° 回転および X 方向反転によるデータ拡張により、訓練データをさらに 8 倍に増やした。なお、切り出した風速・風圧分布は、切り出し範囲外の建物状況によって特に X-Y 平面の縁付近の風速・風圧分布が異なるため、X-Y 平面の周囲約 1 割 (7px) を損失関数の計算対象外 (予測対象外) とした。

訓練は、テスト用データにおいて過学習が発生していないことを確認したうえで、訓練用データの損失関数の値がほぼ収束するまで行った。以上の訓練によって得られる 3D-CNN の出力は、RANS モデル定常計算の結果を教師データとしていることから平均風速 (3 成分) および平均風圧に相当する。

3. 予測結果

3.1 概要

高層建物 2 棟 (建物 A, 建物 B) が隣接するテスト用市街地データ (図-4) を学習済みモデルに入力し、16 風向分の風速・風圧に関するボクセルデータを出力した。所要時間は GPU (Nvidia Tesla V100) を用いて数秒であった。ここでは、代表 2 風向を対象として CFD の結果と比較することにより、3D-CNN における風速・風圧分布の予測精度を検証する。建物形状 (高さ 5m における平面)、風向および定量的評価のための風速・風

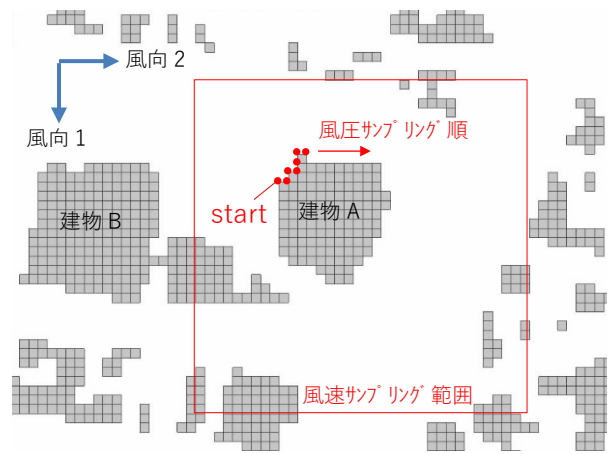


図-4 建物形状 (高さ 5m), 風向およびサンプリング位置
Fig.4 Building shape, wind direction and sampling point

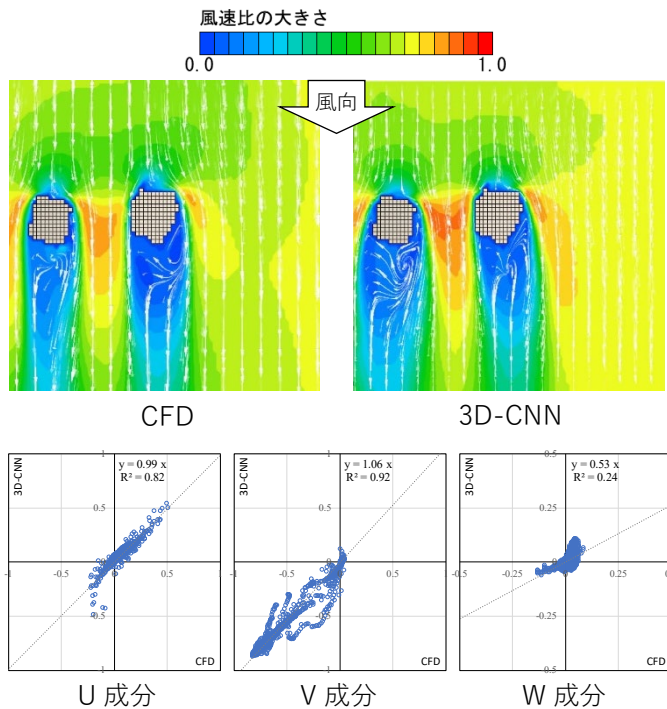


図-5 CFD と 3D-CNN の結果比較 (風向 1, 上層)
Fig.5 Comparison of CFD and 3D-CNN(wind direction 1, Upper)

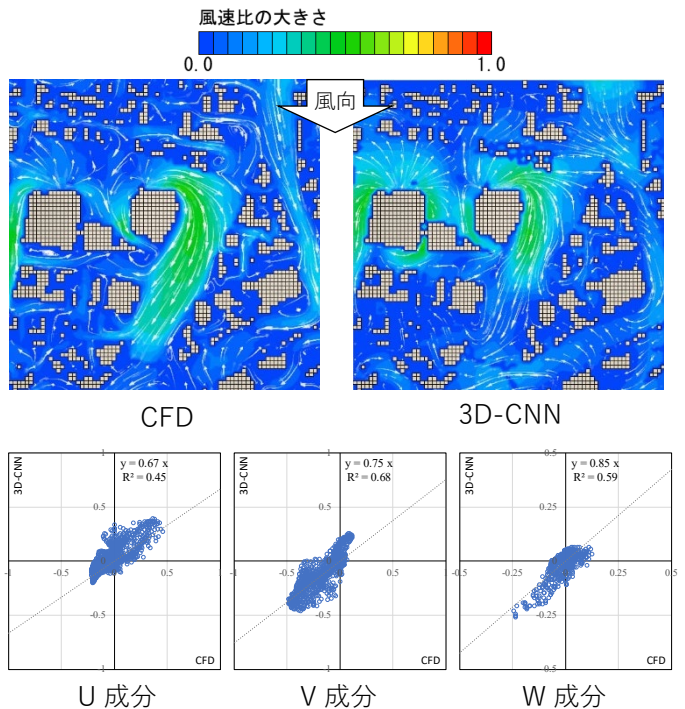


図-6 CFD と 3D-CNN の結果比較 (風向 1, 下層)
Fig.6 Comparison of CFD and 3D-CNN(wind direction 1, Lower)

圧サンプリング位置は図-4 に示す通りであり、建物 A を検証対象として風速は同図の赤枠に示す範囲内のピクセル値、風圧は建物 A 周りのピクセル値をサンプリングする。

3.2 風速分布の予測精度

建物 A, B が風直交方向に並ぶ風向 1 のときの上層 (高さ 80m) および下層 (高さ 5m) の 2 平面における風速の結果比較を図-5 および図-6 に示す。同図には可視化した風速の大きさ・流線の分布図およびサンプリングした風速を基に横軸を CFD, 縦軸を 3D-CNN とした相関図を示している。なお、分布図、相関図ともに 0~1 の出力値を高さ 450m の風速に対する比 (風速比) に相当する -1~1 に変換している (CFD の結果も同様に -1~1 に基準化)。図-5 に示す上層は建物 A, B 周りの風速分布であり、隅角部からの剥離に伴う増速, 2 棟間の増速域および建物背後の後流域が CFD の結果に近い精度で再現されている。相関図で見ると、増速域、後流域の形成位置のずれに起因する若干の差異は見られるものの、U 成分, V 成分ともに CFD 結果に対し高い相関係数 R² が得られている。鉛直 W 成分の相関は低い、絶対値が小さいため影響は小さい。

図-6 に示す下層は建物 A, B の周囲に中低層建物が林立する状況であり、上層よりも複雑な風速分布である。建物 A, B 周りに着目すると、いわゆる「ビル風」に相当する隅角部付近からの増速, 吹き降ろしによる

逆風が CFD に概ね近い精度で再現されている。相関図で見ると、図-5 の上層での結果に比べ相関は低くなるものの、周辺建物の影響が表れる複雑な風速分布の大局的な特徴は捉えられていると考えられる。

建物 A, B が風方向に並ぶ風向 2 のときの上層 (高さ 80m) および下層 (高さ 5m) の 2 平面における風速の結果比較を図-7 および図-8 に示す。図-7 に示す上層は風上側となる建物 B の剥離に伴う増速域ならびに建物 B の後流域に位置する建物 A の周囲に増速域が形成されない特徴が CFD の結果に近い精度で再現されている。しかし、増速域の範囲がやや狭い、後流域の範囲がやや広いなど、風向 1 の場合に比べやや予測精度は落ちている。相関図で見ると、卓越する U 成分で高い相関係数となっているが、CFD の結果に比べやや過小評価の傾向である。建物 2 棟が風方向に並ぶ場合、風直交方向に並ぶ場合に比べ建物間の流れの相互作用が複雑であると考えられ、本研究で用いた訓練データでは建物の形状や相対位置関係に応じて形成される風速分布の微妙な違いや特徴を十分に学習できていない可能性が考えられる。

図-8 に示す下層はさらに周囲の中低層建物の影響が加わることでより複雑な風速分布となっており、CFD の結果に比べ特に建物 A, B の後流域での流れに差異が見られる。相関図で見ると、各成分とも絶対値が小さいものの相関が低く、CFD 結果に比べ過小評価の傾向

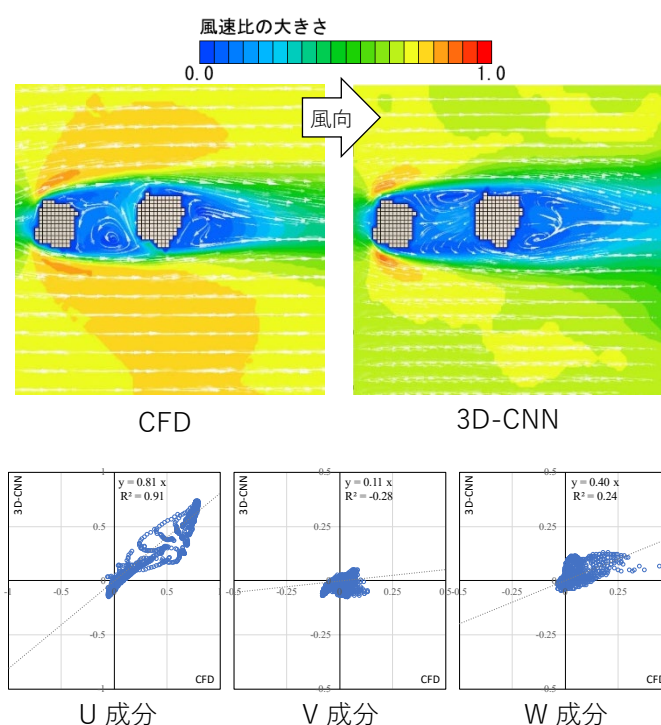


図-7 CFD と 3D-CNN の結果比較 (風向 2, 上層)
Fig.7 Comparison of CFD and 3D-CNN(wind direction 2, Upper)

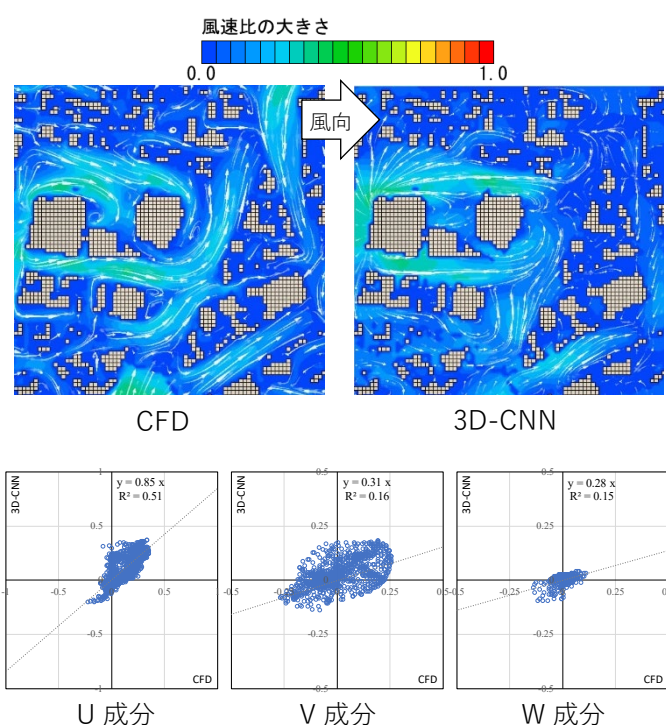


図-8 CFD と 3D-CNN の結果比較 (風向 2, 下層)
Fig.8 Comparison of CFD and 3D-CNN(wind direction 2, Lower)

である。本稿で用いた学習モデルでは、絶対値の大きい部分にフィッティングするよう訓練されていると考えられ、今後、絶対値の小さい部分も精度良く再現できるような学習モデル、損失関数および入出力データの構成などを検討する必要があると考えられる。

3.3 風圧分布の予測精度

次に、建物表面の風圧分布について、風向 1 および風向 2 における予測結果の比較を図-9 および図-10 に示す。風圧分布のコンター図はボクセルデータの各画素を節点に置き換え、CFD 可視化ソフトを用いて可視化した結果である。また、3D-CNN モデルの出力は風速および風圧の 3 次元空間分布を表したものであり、建物表面は 3D-CNN モデルの出力層において建物形状データの建物部分 0 が乗じられることから風圧の値を保持していないため、ここでは隣接する節点（画素）の値の平均値を便宜的に与えている。風圧は建物 A 頂部での速度圧を基準とした風圧係数に換算している。同図下段には、図-4 に示す順でサンプリングした建物 A の高さ比 (z/H) 0.8 および 0.2 の建物表面における全節点の平均風圧係数 C_{pm} の比較を示している。

図-9 の風向 1 の場合、建物 A,B ともに風向に正対す

る風上面が正圧、側面・風下面が負圧となる風圧分布に加え、淀み点付近がピークとなる正圧分布、剥離点に近い側面の風上側隅角部付近の負圧が強くなる特徴が再現できている。一方、本来負圧が生じる屋根面の風上側端部の一部に表れている正圧は、建物表面の風圧を隣接する節点の平均値として便宜的に与えたことによる影響と考えられる。同図下段に示す風圧係数の比較で見ても、風上面の正圧および側面・風下面の負圧分布について各高さとも CFD に近い結果が得られている。

図-10 の風向 2 の場合、建物 A が建物 B の後流域に入ることによって全ての面ではほぼ負圧となる影響が明確に再現されている。しかし、同図下段に示す風圧係数の比較にも表れているように CFD に見られる一部の正圧は再現できておらず、精度改善の余地が見られる。

4. おわりに

建物周辺の風速・風圧分布予測に 3D-CNN を適用するため、予測精度について検討した。本稿で用いたテスト用市街地モデルでは、一部に学習不足等に起因す

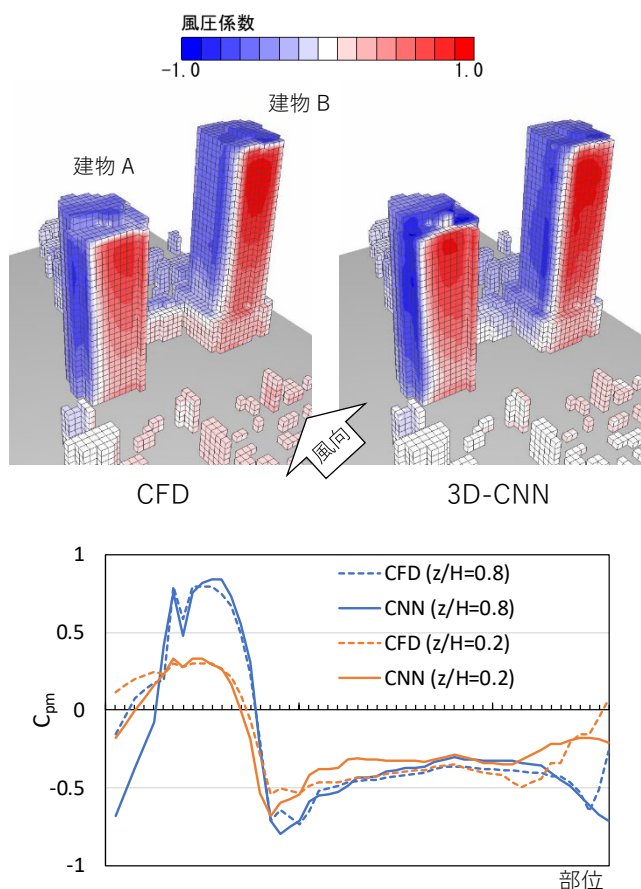


図-9 CFD と 3D-CNN の結果比較 (風向 1)

Fig.9 Comparison of CFD and 3D-CNN (wind direction 1)

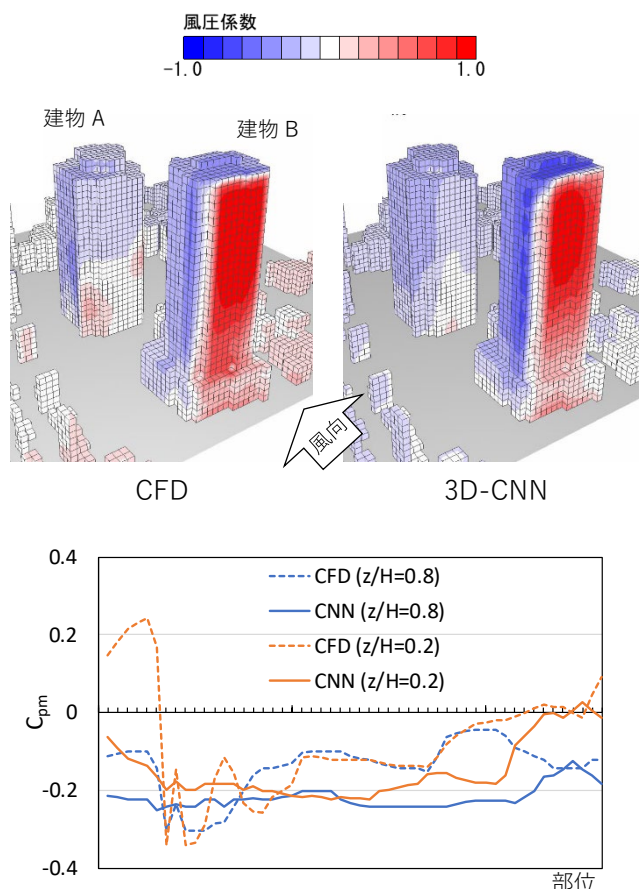


図-10 CFD と 3D-CNN の結果比較 (風向 2)

Fig.10 Comparison of CFD and 3D-CNN (wind direction 2)

ると考えられる差異が見られたものの、大局的には CFD 結果に近い予測結果が得られた。

以下に、いくつかの課題を述べたい。本研究では前述の通り CNN をサロゲートモデルとして用いている。一般に訓練によって得られた CNN の膨大なパラメータの各々の意味・役割は解読不能（ブラックボックス）であるため、予測精度は担保できず、流体の支配方程式を物理的に満足する予測結果が得られる保証はない。また、予測精度は訓練データの質と量に依存する。本研究では、現段階では主に高層建物を中心とした市街地の CFD 結果を訓練に用いているため、例えば大スパン建築物における予測精度は現状あまり期待できない。このような問題は訓練データの質や量の偏りにより学習モデルも偏りのある結果を出力してしまう「バイアス問題」として一般に認知されている。訓練データは量的・質的に均質であることが重要であるとともに、訓練された学習モデルにバイアスが含まれていないか（不公平・不平等な答えを出力しないか）、注意深く検証する必要がある。そのため、一般的な深層学習のサロゲートモデルを高い予測精度が求められる用途に適用する場合には慎重な検討が要求される。本稿に示した AI 技術においても、現段階では予測結果の妥当性を担保できないため、最終的には風洞実験または CFD で確認・評価する必要がある。近年提案された Physics-Informed Neural Networks (PINNs)⁸⁾ と呼ばれる学習モデルは物理的に満足する出力が得られるため、予測結果の妥当性を要求される用途への利用が今後期待される。

以上、本技術は現状いくつかの課題を抱えているものの、建物周りの風速・風圧分布を極めて簡易かつ短

時間に得られる特徴は従来技術にはない長所であり、風環境計画等のフロントローディングに多大に貢献できる可能性があると考えられる。今後、学習データの充実とともに、学習モデルやデータ構成等の工夫により予測精度の改善を図っていく予定である。

参考文献

- 1) 加藤 優輝：曇み込みニューラルネットワークを用いたビル風予測手法に関する研究－単体建物を対象とした風速分布予測－，日本建築学会大会学術講演梗概集(中国)，構造 I，pp.147-148, 2017.
- 2) 田中 英之，川上 沢馬，松岡 康友，畔上 泰彦：曇み込みニューラルネットワークによる建物周辺気流の予測精度」，日本建築学会大会学術講演梗概集(北陸)，環境工学 I，pp.805-806, 2019.
- 3) 山本 耕平，遠藤 智行：深層学習による建物壁面における風圧係数分布予測に関する基礎的検討－（その 1）未学習の建物形状についての予測における予測精度の検討－，日本建築学会大会学術講演梗概集(関東)，情報システム技術，pp.109-110, 2020.
- 4) 中村 良平，吉川 優：人工知能(AI)を用いた市街地風環境予測技術の開発，大成建設技術センター報，第 52 号, 2019.
- 5) 中村 良平：3D-CNN を用いた建物周辺の風速分布予測に関する研究，風工学シンポジウム講演梗概集，第 26 巻，pp.162-166, 2020.
- 6) 岡谷 貴之：深層学習，講談社, 2015.
- 7) Çiçek Ö., Abdulkadir A., Lienkamp S.S., Brox T. and Ronneberger O., : 3D U-Net: Learning dense volumetric segmentation from sparse annotation, in International conference on medical image computing and computer-assisted intervention, Springer, pp.424-432, 2016.
- 8) Raissi M., Perdikaris P. and Karniadakis G.E., : Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, J. Comput. Phys., vol.378, pp.686-707, 2019.