

# 畳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の開発 — 単体建物を対象とした風速分布予測 —

加藤優輝 \*

本論文は、畳み込みニューラルネットワークを用いて建物近傍の風速分布予測を行ったものである。建物の情報を有する3種類の画像とCFD (Computational Fluid Dynamics) 解析により得られた風速分布画像を畳み込みニューラルネットワークに学習させ、学習した畳み込みニューラルネットワークにより風速分布を予測する。本論文では、その第一段階として予測手法の概要、本論文で用いた畳み込みニューラルネットワークの基本的な構造、単体建物を対象とした風速分布予測結果について述べる。

キーワード：ビル風、風速分布予測、畳み込みニューラルネットワーク、CFD

## 1. はじめに

高層・超高層建物の建設に伴う風害(ビル風)を評価する方法として風環境評価がある。風環境評価を行うために建物周辺に作用する風速を求める必要があり、その方法として風洞実験とCFD (Computational Fluid Dynamics) 解析が挙げられる。特に、CFD 解析はコンピュータの進歩とともに風洞実験に代わる方法となりつつある。

CFD 解析は幅広い分野で使用されており、以下のような場合にも活用できる可能性がある。例えば、設計の初期段階から建物周辺の風環境を把握しながら計画できれば、より風環境に配慮した建物が設計できる。また、建物施工時においては、施工段階に合わせて変化する風環境を把握することができれば、建設現場における風災害の防止に役立つ。

しかしながら、CFD 解析を行うために要する作業量、解析環境の整備、必要とされる専門知識などから、一部の場を除き上記のような方法が手軽に行えるとは言い難い。また、上記の場合に求められる結果は、一般的な風環境評価に求められる結果とは異なり、風洞実験と良く対応するような精度の高い結果が得られることよりも、ある程度の精度を保ちながら簡便にかつ短時間で結果が得られることが重要と考えられる。

これらを解決する手法として、畳み込みニューラルネットワーク (Convolutional neural network: 以下 CNN) を用いたビル風予測手法を提案する。ニューラルネットワークは、人間の脳神経系を模倣した数理的モデルであり、中でも CNN は、画像分野での一般物体認識において優れた結果を残している。ニューラルネットワークを多層・深層化したものはディープラーニングとも呼ばれ、様々な分野で応用技術の開発・運用が行われている。し

かしながら、風工学分野におけるニューラルネットワークを応用した研究例<sup>1),2)</sup>は非常に少ない。

本論文で提案するビル風予測手法は、建物の情報を有する3種類の画像とCFD 解析より得られた風速分布画像をデータベースとしてCNN を学習させ、学習したCNN によりデータベースに含まれない未知の風速分布を予測させるものである。これにより、建物周辺の風環境を対象としたCFD 解析に比べ、必要なパラメータを少なくかつ簡単にすることができる。さらに、予測時におけるCNN の計算量は反復計算が必要なCFD 解析より遥かに少ないため、CFD 解析に比べ短時間で結果を得ることができる。したがって、流体解析の専門知識を持たない者でも短時間である程度の精度を保ったまま風速分布を予測できるようになる。

以上のことから、本論文は、CNN を用いたビル風予測手法の概要を述べるとともに、解析の一例として単体建物の風速分布予測について述べる。

## 2. ビル風予測手法

本章では、提案するCNN を用いたビル風予測手法の概要について述べる。本予測手法の全体的な流れを Fig. 1 に示す。予測の対象となる建物の条件は、図中 Input map に示す3種類の画像データから構成される。Height は予測する高さ、Shape は建物の断面形状、Direction は対象とする風向をそれぞれ表している。これらの画像をCNN に入力することで演算が開始される。

入力された画像を受け取ったCNN は、各層で畳み込み (Convolution) またはその逆動作である逆畳み込み (Deconvolution) を行い、図中 Output map1 を出力する。Output map1 とCFD 解析より得られた風速分布画像を比較し、各ピクセルあたりの誤差が算出される。算出された誤差は誤差逆伝播法 (backpropagation) により各層に伝

\*技術研究所 風環境研究グループ

播していき、重みが更新される。ここまでの処理を繰り返すことで CNN の重みとバイアスが逐次更新され、建物周辺の風速分布の予測が可能となる。最後に、学習した CNN を用いて任意の建物周辺の風速分布を予測させ、図中 Contour map を作成する。なお、畳み込み層・逆畳み込み層・誤差逆伝播法の計算アルゴリズムの詳細については各種書籍<sup>た</sup>たとえば<sup>3), 4)</sup>などに数多く記されている。

次に、入力データの詳細について説明する。Height の詳細図を Fig.2 に示す。Height は予測する高さに応じて色の濃淡を段階的に変化した画像であり、本論文では、地表面を 0 (黒)、対象建物頂部を 255 (白) と定義した。Shape は予測高さにおける断面図に相当する画像であり、建物もしくは障害物が存在する部分を白と定義した。Direction の詳細を Fig.3 に示す。Direction は風上から風下にかけて画素値が小さくなるグラデーション画像である。風向変化は画像そのものを回転させることで再現している。ここまで入力画像について説明したが、入力データはいずれも簡単な仕組みの画像である。特に Height や Direction については、プログラム上で予め定義しておけば画像を作成する必要がない。すなわち、風速分布を予測するための手間がほとんどかからないという利点がある。また、CFD 解析は風環境分野における主流な解析方法のひとつであり、既に数多くの解析結果が存在する。したがって、これらを活用することができれば様々な条件の流体解析結果を学習することができる。すなわち、より様々な条件に応じた風速分布を予測できるようになると考えられる。

### 3. 単体建物の風速分布予測

本章では、ビル風予測手法の予測精度の検証として、単体建物を対象とした風速分布予測を行う。CFD 解析より得られた風速分布を用いて CNN の学習と予測を行い、その予測精度について検討する。

#### 3.1 学習モデル

学習と予測に用いる CNN の学習モデルを Table1 に示す。Table1 の Filter・Stride・Padding・Output の構成は、CNN を用いてラフ面のクリーンアップを行っている参考文献<sup>5)</sup>の構成を参考に決定した。なお、本論文では参考文献中の upconvolution を Deconvolution とした。

学習モデルは入力された  $64 \times 64$  の 3 枚の画像に対して畳み込みと逆畳み込みを繰り返し、 $64 \times 64$  の 1 枚の画像を出力する。入力画像は  $0.0 \sim 1.0$  の範囲で正規化している。学習はミニバッチ単位で行われ、1 バッチあたり 80 個の学習データとした。各層ではバッチ正規化処理が行われており、活性化関数は出力層を式(1)に示す Sigmoid 関数、それ以外を式(2)に示す ReLU (Rectified Linear Unit) とした。なお、今回用いた学習モデルにプーリング層は存在しない。プーリング層は、画像の解像度を低下させる動作を行うため、画像生成には適さないと判断したためである。学習時の誤差関数は二乗平均誤差とし、コンター処理を行う前の画像 (Fig.1 Output map) と CFD 解析結果との誤差を比較している。学習率の調整方法は

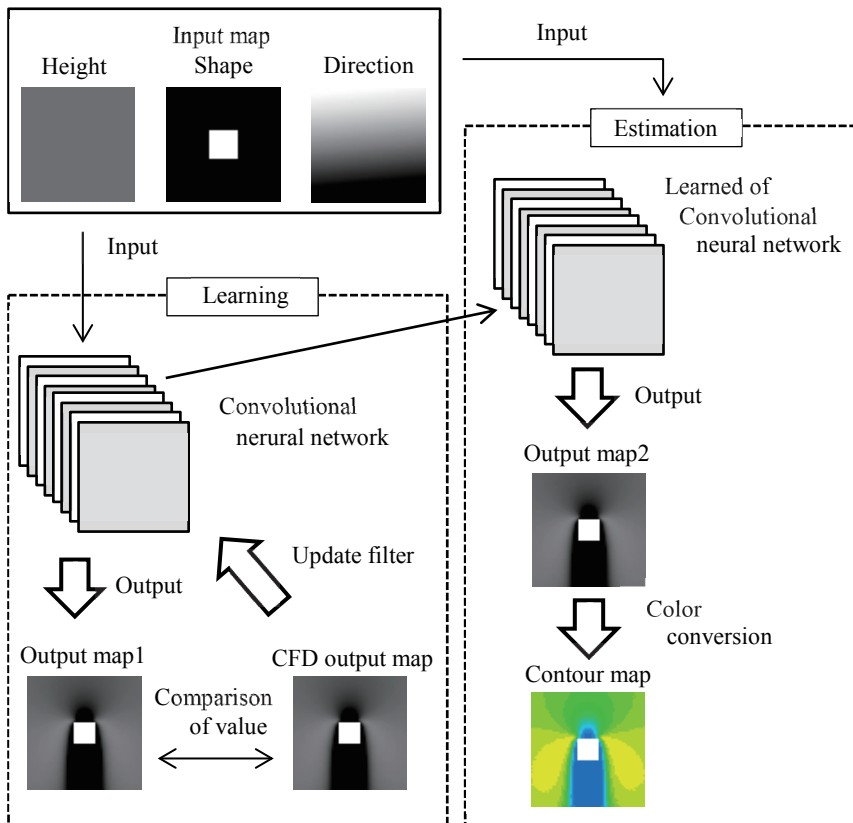


Fig.1 学習および予測手法概要




Fig.2 Height 概要




Fig.3 Direction 概要

Adam<sup>6)</sup>を採用した。以上の構成のプログラムをプログラミング言語Pythonとそのオープンソースライブラリであるchainer<sup>7)</sup>を用いて作成した。

Table 1 学習モデル

	Filter	Stride	Padding	Output
Input				64×64×3
Convolution 1	5×5	2	2	32×32×48
Convolution 2	3×3	1	1	32×32×128
Convolution 3	3×3	1	1	32×32×128
Convolution 4	3×3	2	1	16×16×256
Convolution 5	3×3	1	1	16×16×256
Convolution 6	3×3	1	1	16×16×256
Convolution 7	3×3	2	1	8×8×256
Convolution 8	3×3	1	1	8×8×512
Convolution 9	3×3	1	1	8×8×1024
Convolution 10	3×3	1	1	8×8×1024
Convolution 11	3×3	1	1	8×8×1024
Convolution 12	3×3	1	1	8×8×1024
Convolution 13	3×3	1	1	8×8×512
Convolution 14	3×3	1	1	8×8×256
Deconvolution 1	4×4	2	1	16×16×256
Convolution 15	3×3	1	1	16×16×256
Convolution 16	3×3	1	1	16×16×128
Deconvolution 2	4×4	2	1	32×32×128
Convolution 17	3×3	1	1	32×32×128
Convolution 18	3×3	1	1	32×32×48
Deconvolution 3	4×4	2	1	64×64×48
Convolution 18	3×3	1	1	64×64×24
Convolution 19	3×3	1	1	64×64×1

$$a_{\text{sigmoid}}(x) = (1 + \exp(-x))^{-1} \quad (1)$$

$$a_{\text{ReLU}}(x) = \max(0, x) \quad (2)$$

### 3. 2 動作環境

CNNの学習と予測は自作PCを用いて行った。PCの構成は、OS: Windows7 64bit, CPU: Intel Core i7-5820K 3.30GHz, RAM: 64.0 GB, GPU: NVIDIA GEFORCE GTX1080である。

### 3. 3 学習および予測データ

学習と予測精度の検討に用いる風速分布画像はCFD解析ソフト「STREAM」により作成した。対象とする建物はアスペクト比5の正方形角柱である。風速分布はモデル頂部風速を基準とする風速比として表し、グレースケール表示とした。また、分布の簡略化のため、風速比0.3

以下は一律同色とした。対象とする風向の範囲は、学習時のデータは0~90°の5°区切り計19風向とし、予測時のデータは同範囲において22.5°区切り計5風向とした。高さ方向については、学習時で51枚、予測時で50枚とし、学習時と予測時で同一高さとならないよう設定した。したがって、学習時と予測時では、同風向のデータ(例えば45°, 90°)は存在するが、同一高さのデータは存在しない。本来、風向と高さの両方が重複しないよう学習時と予測時のデータを設定すべきであるが、設計時における建物周辺の風環境は16風向の結果に基づき評価されることから、16風向に該当する風向については重複していても問題ないと判断した。

これらの条件に合わせてデータセットを作成し、それぞれ学習データ、予測データとした。なお、風速分布画像の全枚数は学習データで19×51=969枚、予測データで5×50=250枚である。

### 3. 4 学習および予測結果

Fig.4に学習曲線を示す。図から学習回数(Epoch)が進むにつれて誤差が減少している様子が確認できる。学習が進むにつれて学習時(表中 train)の誤差と予測時(表中 test)の誤差が解離する過学習の兆候が見られたため、学習を1500回で打ち切った。

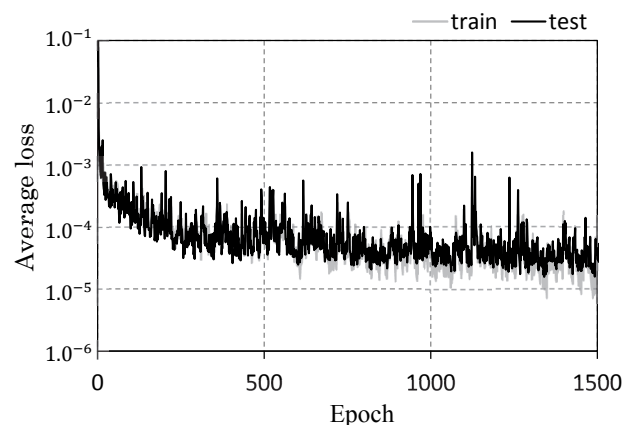
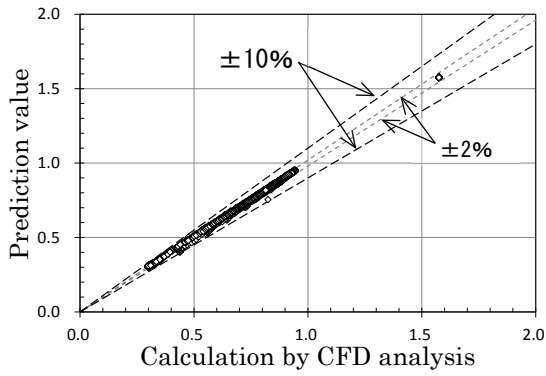



Fig.4 学習曲線

次に、予測精度の検討を行った。予測精度の検討は予測された画像とCFD解析より得られた画像の各ピクセルの画素値を風速比に換算し相対誤差として評価した。したがって、画像一枚当たり4096個が評価対象である。Fig.5に風向 $\theta=0^\circ$ 、高さ比 $h/H=0.45$ 、および予測結果の中で最も精度が低いと判断された $\theta=22.5^\circ$ 、 $h/H=0.97$ の比較結果を示す。なお、図中点線はそれぞれ相対誤差 $\pm 2\%$ 、 $\pm 10\%$ の範囲を表している。結果より、 $\theta=0^\circ$ 、 $h/H=0.45$ は、風速比によらず高い精度で予測されている。これに対して、 $\theta=22.5^\circ$ 、 $h/H=0.97$ は風速比の小さい領域において過大に予測している。しかしながら、強風領域の精度が良好であり、さらに後述するコンター図の比較からも予測精度に問題はないと判断できる。



a)  $\theta = 0^\circ$   $h/H = 0.45$



b)  $\theta = 22.5^\circ$ ,  $h/H = 0.97$

Fig. 5 CFD 解析結果と予測値との相関

Fig. 6 に予測対象とした全データにおける予測誤差  $\pm 2\%$  以下の割合を示す. Fig. 6 より,  $h/H < 0.9$  の領域では, 予測誤差  $2\%$  以下が全体の  $90\%$  以上を示している. これに対して,  $h/H > 0.9$  の領域では, 相対誤差が大きくなるものの全体の  $80\%$  以上が相対誤差  $2\%$  以内に収まっている.


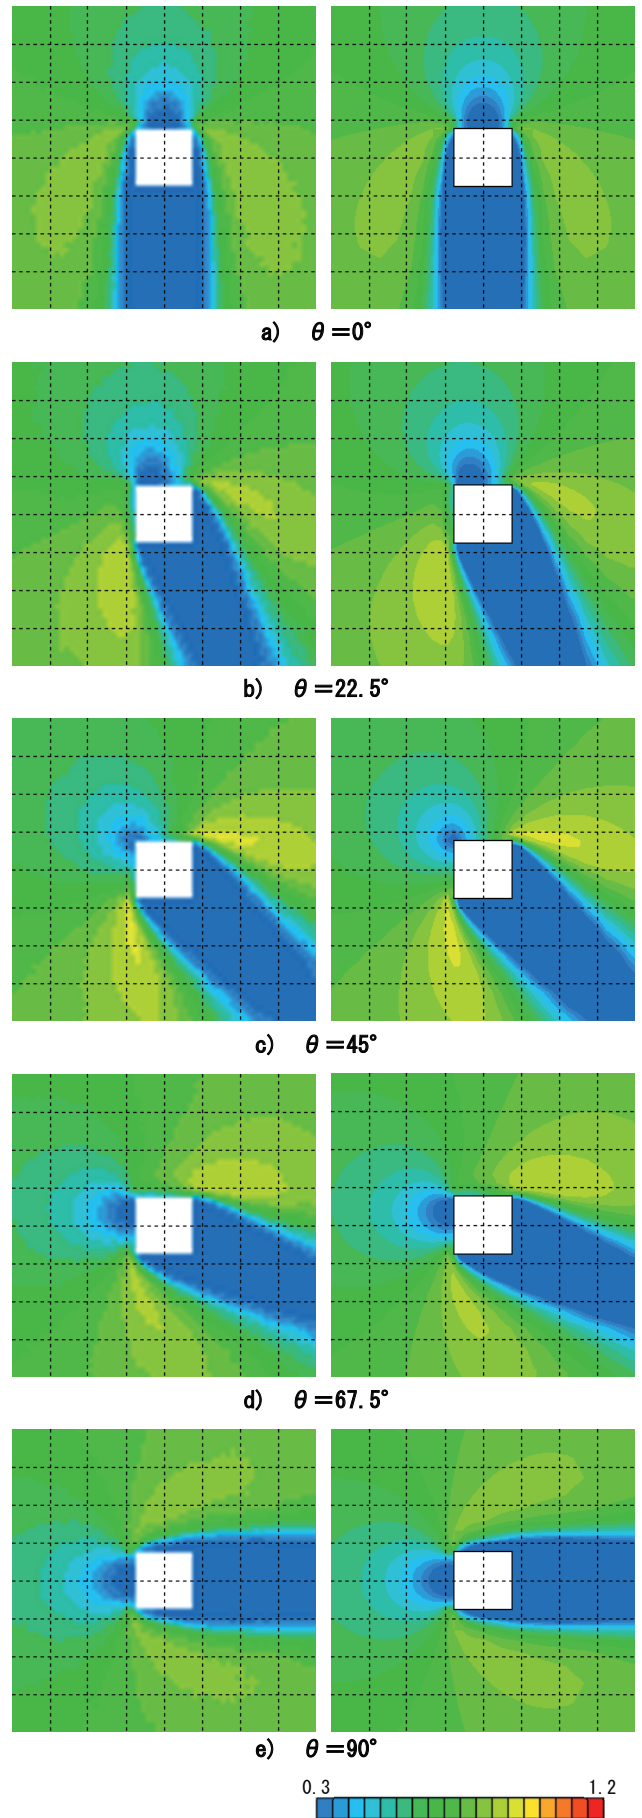


Fig. 6 予測誤差  $\pm 2\%$  以内の占める割合

Fig. 7~9 に予測時と CFD 解析結果のコンター図の比較を示す. コンター図の比較は  $h/H = 0.09, 0.45, 0.97$  を対象とした. 予測時のコンター図は  $64 \times 64$  ピクセルの画像であるが, CFD 解析結果のコンター図は,  $256 \times 256$  ピクセルの画像として比較を行っている.

結果より, 画像の解像度の違いにより鮮明さが異なるものの, 強風領域の範囲や値などが良く再現できている. 最も予測精度の低い  $\theta = 22.5^\circ$   $h/H = 0.97$  においても, 視認による判断では, 強風領域が再現されており十分な精度であると判断できる.




e)  $\theta = 90^\circ$




左: 本予測手法 右: CFD 解析


Fig. 7 CFD 解析との比較 ( $h/H = 0.09$ )




a)  $\theta = 0^\circ$




b)  $\theta = 22.5^\circ$



c)  $\theta = 45^\circ$



d)  $\theta = 67.5^\circ$




e)  $\theta = 90^\circ$




左：本予測手法 右：CFD 解析


Fig. 8 CFD 解析との比較 ( $h/H=0.45$ )




a)  $\theta = 0^\circ$




b)  $\theta = 22.5^\circ$



c)  $\theta = 45^\circ$



d)  $\theta = 67.5^\circ$



e)  $\theta = 90^\circ$



左：本予測手法 右：CFD 解析

Fig. 9 CFD 解析との比較 ( $h/H=0.97$ )

以上の結果から、単体建物のみを対象とした場合ではあるが、本予測手法が有効と判断できる。高い精度で予測することができた要因として、十分な学習データの数を揃えられたこと、全結合層とプーリング層を採用せずに畳み込み層と逆畳み込み層のみで構成されたネットワークを採用したことが挙げられる。

学習データの充実、ニューラルネットワークを学習させる上で最も重要な項目の一つである。本予測手法は、CFD 解析モデルの作成から学習データの出力までが PC 内で完結しているため、一度環境を構築すれば人手をかけずに十分な量の学習データを用意できる。

ネットワークの構成については、全結合層は畳み込み層に比べ過学習しやすく、プーリング層は画像生成に必要な情報量を低下させる可能性がある。これらを採用しなかった結果、精度良い予測結果が得られたと考えられる。

本予測手法を用いた場合、風工学や流体解析に習熟していなくとも、簡便に建物周りの風速分布を予測することができる。

#### 4. まとめ

本論文は、CNN を用いたビル風予測手法の概要と単体建物を対象とした風速分布予測について述べた。

$h/H > 0.9$  の範囲で相対誤差が大きくなる傾向にあるが、いずれの場合も全体の 80% 以上で誤差 2% 以内に収まっている。

強風領域の範囲や値などが良く再現できていることが確認できる。

これらの結果から、単体建物のみを対象とした場合ではあるが、本推定手法が有効と判断できる。

今後は、CNN の学習モデルの改良を進めるとともに、複数の建物が配置された場合や建物形状が変化した場合について CNN を用いた風速分布予測の検討を進めていく。

#### 参考文献

- 1) 植松 康, 鶴石 楽, 本郷 剛, 菊池浩利: 大空間構造の屋根葺き材の耐風設計における次世代風荷重評価システムの開発研究, 膜構造研究論文集 2006, No. 20, pp. 1-12, 2006
- 2) 佐々木 亮治, 佐藤 健一: ニューラルネットワークを用いた建物壁面風圧予測, 西松建設技報 Vol. 30, pp. 119-120, 2007
- 3) 岡谷貴之: 機械学習プロフェッショナルシリーズ 深層学習, 講談社, 2015. 4
- 4) 人工知能学会監修: 深層学習—Deep Learning—, 近代科学社, 2015. 10
- 5) Edgar Simo-Serra, Satoshi Iizuka, Kazuma Sasaki, Hiroshi Ishikawa: Learning to Simplify: Fully Convolutional Networks for Rough Sketch Cleanup, ACM Transactions on Graphics (SIGGRAPH), 2016. 7
- 6) Jimmy Ba and Diederik P. Kingma: Adam: A method for stochastic optimization, In Proceedings of International Conference on Learning Representations, 2015
- 7) <https://github.com/pfnet/chainer>

---

## Development of the prediction method for strong wind around buildings using convolutional neural network -Wind velocity distribution predication of a building-

Yuuki KATOH

#### Abstract

This paper is described for wind velocity distribution prediction around a building using the convolutional neural network. Convolutional neural network is trained with wind velocity distribution image calculated from CFD analysis and three type images with the information of a building.

As the first step, this paper describes an overview of prediction method, the basic structure of the convolutional neural network and the results of the wind velocity distribution prediction intended for a building.

Keywords: Strong wind around buildings, Wind velocity distribution predication, Convolutional neural network, CFD

---