

# 深層学習を用いた建物通風の気流予測に関する研究

## 東京電機大学千住キャンパス千住東書庫棟を例として

### Research on airflow prediction of building ventilation using deep learning

#### Library Building of Tokyo Denki University as an example

○池田 開<sup>\*1</sup>, 小笠原 正豊<sup>\*1</sup>

Kai IKEDA <sup>\*1</sup>, Masatoyo OGASAWARA <sup>\*2</sup>

\*1 東京電機大学大学院 修士課程

Master's Course, Department of Architecture, Graduate School of Tokyo Denki University

\*2 東京電機大学未来科学部建築学科准教授・博士 (工学)

Associate.Prof., Tokyo Denki University, Dr.Eng.

キーワード : 深層学習; CNN; 通風; 風速予測; CFD

Keywords: Deep learning; Convolutional neural network; Ventilation; Wind speed prediction; Computational Fluid Dynamics.

## 1. はじめに

### 1.1. 背景

近年、環境問題に伴い省エネルギーに対する意識が高まり、ZEB や ZEH を実現していくことが強く推奨されている。またこれらの対策として、電機やガス、熱等のアクティブなエネルギーの削減とともに、自然風や太陽光などパッシブなエネルギーを利用することでより大きな効果を得る事が出来る。

風や熱の利用については、CFD(Computational Fluid Dynamics)解析を用いた設計手法がしばしば用いられ、風の流れや熱の分布等を可視化し検討を行う事で、より精度の高い環境配慮型の建築物の設計に寄与している。しかしながら、CFD 解析を用いるためには、解析環境の整備や解析条件に関する高い専門性を必要とする為、容易な使用が出来ない等の問題も抱えている。また、風洞実験の様なより良い精度を求めた解析を行うためには解析時間がかかる。設計初期などの検討案を多量に出す段階では、ある程度の精度を保ちつつ瞬発的な解析結果の表示による設計補助の役割を果たしていく事が重要である。

これらの解決手法として、CFD 解析ツールではなく CNN(Convolutional neural network)を用いた風予測手法が着目されつつある。CNN を用いた風予測の手法としては、加藤の研究<sup>1)</sup> や田中らによる研究<sup>2)</sup>、周らによる研究<sup>3) 4)</sup> などが行われているが、建物室内の通風検討に対しての研究はまだ十分とは言えない。

### 1.2. 目的

本研究は、CNN を用いた建物室内における通風の風予測手法の概要を述べるとともに、風予測の一例として CFD 解析の結果と CNN での予測結果の比較を行う事を目的とする。

## 2. 研究手順

CNN による学習データセットの作成にあたり多量の解析画像が必要となる。そこでまず初めに、解析にかかる時間を抑え込みつつもある程度の解析精度を保つことの出る解析条件を作成する。そこで、まず最初に実際の建物で計測した値を目標値とし解析条件の比較検討を行う。また、3D モデルの作成及び解析条件の付与には Rhinoceros のプラグインツールである grasshopper を使い、解析には FlowDesigner2020 を使用した。次に、作成した解析条件を用いて開口部の位置と幅を変更させたデータセットを作成・学習を行う。最後に、学習に対する推論として未知のデータを与え、CFD 解析の結果と比較検討を行う(図 1)。

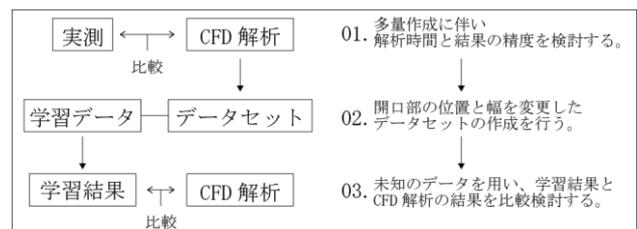


図 1. フローチャート

## 3. 実測に伴う CFD 解析の精度検証

### 3.1. 研究方法

まず初めに、東京都足立区に所在する東京電機大学千住東書庫棟の一室である実験管理室(x:7m, y:4.5m, z:2.5m)を対象として計測を行う。計測は、千住東書庫棟の屋根面より 2m 高さを設けた地上 6.5m での卓越風の測定と地上 1.7m での各開口部における部屋内部への流出入に関して行う(図 2)。また、実測期間は、令和 2 年 7 月 29 日~8 月 21 日である。測定機器は、NETATMO 社の netatmo ウェザーステーション風速計モジュールを使用し計測を行った。

次に、地点 a での実測をもとに風向風速を決定し CFD 解析の解析結果と各開口部における実測結果の比較を行う。CFD 解析条件については図 3 にモデルと解析範囲に関しては図 4 に示す。

### 3.2. 実測と CFD 解析の比較

風速 3.0m/s(地点 a)に対する実測値と CFD 解析値との比較結果(表 1)より、風速の誤差は最大 0.5m/s であり概ね等しい値をとることが確認できた。この事より、データセット作成のためにある程度簡略化させた解析モデルを用いた場合でも、メッシュ数や解析範囲等の解析条件に対する妥当性が確認されたため、これらの解析条件を用いてデータセットの作成を行う。

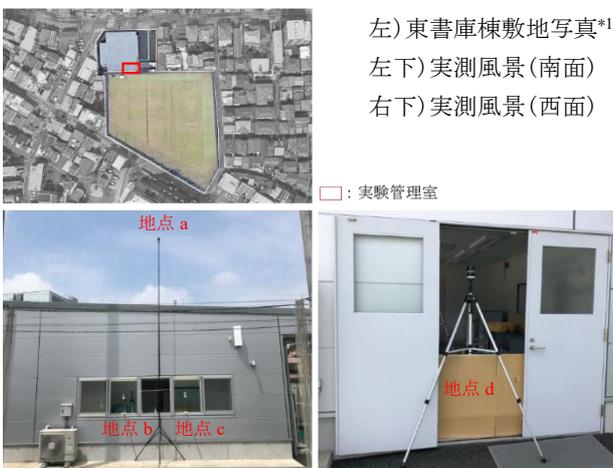


図 2 実測風景

ソフトウェア	FlowDesigner2020	解析範囲	x:56m, y:70m, z:22m
乱流モデル	高レイノルズ数型 /k-ε モデル	風速	3.0m/s(地上 6.5m)
計算アルゴリズム	SIMPLEC(定常解析)	風向	南
移流項差分スキーム	QUICK		

図 3 解析条件

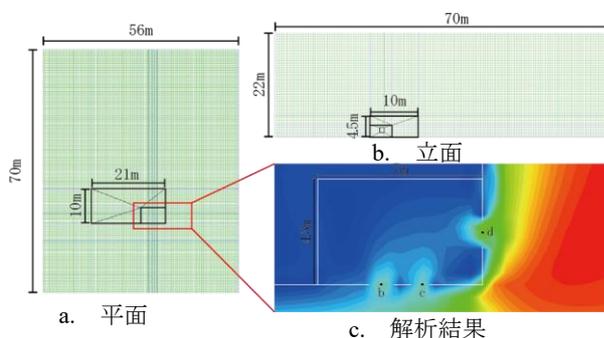


図 4 解析モデル

表 1 比較結果(単位: m/s)

	地点 b	地点 c	地点 d
実測	0.8	1.4	1.9
CFD	0.9	0.9	1.6

## 4. 学習モデルについて

深層学習のライブラリとして keras を用いた。また画像生成アルゴリズムとして pix2pix<sup>5)6)</sup> と呼ばれる 2 枚の画像をペアとして対応関係を学習させることの出来る生成手法を用いた。また、pix2pix では通常の GAN(Generative Adversarial Networks)とは異なり、cGAN(conditional GAN)<sup>7)</sup>を用いることで、Discriminator は Generator によって与えられたデータに対し正解のペアか不正解のペアかを判断する(図 5)。さらに、CNN の構成に対して U-Net<sup>8)</sup>と呼ばれるネットワーク構造を用いる事で、Encoder の各層で出力される特徴マップを Decoder の対応する各層の特徴マップへとスキップ接続させ共通の特徴量におけるデータ欠損を回避させている(図 6)。加えて、Discriminator に PatchGAN を用いることで画像全体ではなく画像の高周波成分となる局所的な領域から画像を判断させている。また、低周波成分については L1 ノルムを組み込むことで補完させ精度を向上させている。

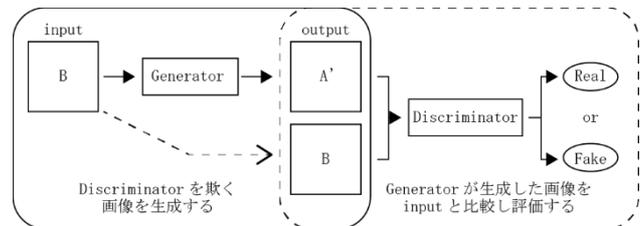


図 5 cGAN の構造

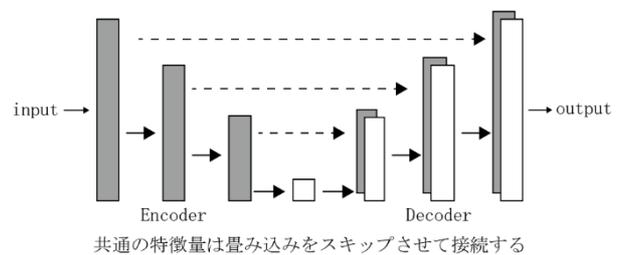


図 6 U-net の構造

## 5. 風予測に関する画像生成

### 5.1 研究対象とデータセット

本章では室内空間における通風気流の予測を対象とし、学習時のパラメータに関する未知のデータに対する予測として、窓の幅や位置を変更したモデルの予測と、学習時には固定していた窓の数や、部屋の大きさ・位置を変更させた未知のデータに対する予測を試みることで、画像生成による予測精度の比較と検証を行う。データセットの作成に際し、開口は外壁に対し 1 つずつ幅と位置をずらしながら与えた(図 7)。その他の解析範囲や風速風向等 CFD 上での解析条件は図 3 での条件と同一のものを用る。学習用データセットは約 800 枚用意し、反転による水増しを行い約 1600 枚のペア画像を用いた。

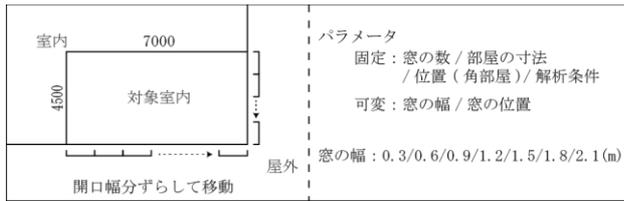


図 7 パラメータの設定

## 5.2 学習済みデータと未学習データの比較

学習させたデータセットに対する推論の結果について学習済み画像を用いた結果と未学習画像を用いた結果を示す(図 8)。学習済み画像を用いた結果に関して、20epoch 程度学習させた時点で、流入出の開口部の位置に対する風速の分布が再現出来ていることを確認した。また、50epoch 程度まで学習させると、流入口からの分布において室内に向かうにつれ濃淡が鮮明に再現された。以降同様な特徴の学習結果が得られた。それに対し未学習画像を用いた結果では、20epoch 程度の学習に対し、流入口に対して開口部の位置に対する大まかな風速分布の挙動が見られ、50epoch 程度まで学習させると、室内に伸びる風速分布が Ground truth の結果により近づくことが確認された。学習済み画像の結果に対し、未学習画像を用いた画像の学習結果では 53epoch 以降正解率が低下していることから過学習を起こしておりモデルとして不適切と判断した。その為、今回のデータセット及び学習条件では epoch 数 53 未満にするべきであり 3 節以降では 48epoch の学習データを用いる。

## 5.3 窓幅と位置の変化と予測結果

データセット作成時のパラメータとして用いた開口部の幅と位置に対して、未知のデータによる予測結果と Ground truth として CFD 解析の結果を比較する(図 9)。より詳細な色の濃淡についてまでは表現しきれていないが、流入口から流出口までの気流の動きについて大方再現できた。

## 5.4 学習時のパラメータ外の変化と予測結果

データセット作成時に固定させていたパラメータを用いて未学習画像を作成し、予測を試みることでこの学習データセットに対する汎用的な利用の可能性について探る。まず開口部の数の制限について、作成時のパラメータでは外壁に対し、1 つずつ設けていたものを 2 つまで増やし予測を行った(図 10)。また、部屋に関するパラメータについて寸法を変化させ予測を行ったもの(図 11)と位置を変えて予測を行ったもの(図 12)について示す。学習時に固定していたパラメータの予測結果として、窓の数と部屋の大きさを変化させた未学習データへの予測結果は、窓の幅と位置の変化に対する予測結果と同様に気流の動きを再現できた。しかし、部屋の位置に対する予測結果については、流

入位置に対する予測を再現することは出来たが、流出入を繋ぐような気流の動きは再現できなかった。原因としては、画像の左右両方が屋外として設定した事や開口部の位置を横ではなく後方へ変更したことから、学習時の特徴に基づく予測を行う事が出来なかった為ではないかと考えられる。

## 6. まとめ

本研究では、CNN を用いた建物室内における通風の風予測手法の概要を述べるとともに、風予測の一例として CFD 解析の結果と CNN での予測結果の比較を行った。本学習データセットを用いた風予測画像の比較として、まず対象室内の認識については位置や大きさを変えた場合においても、対象室内を認識し通風の予測を行える事を確認した。また、窓の位置や幅に関する認識として、正解データに近い気流の動きを予測することが出来た。しかし、色の濃淡に対する再現では詳細な色分けが難しく風速が強い方の色味に影響された。本研究では、可変させるパラメータを開口部の位置と幅に限定し、データ数約 1600 件と少なかった為、風速を再現する色の濃淡や部屋の大きさを変更させたときの対象室内以外の室内空間といった特徴は学習出来なかった。色の濃淡に関する特徴量の抽出については、ハイパーパラメータの操作をさらに行う事でより詳細な再現が可能になるのではないかと推測する。また、室内空間の大きさや位置に関する認識については、そういった特徴を含む学習データをさらに加えていく必要があると推測する。今後の課題としては、データ数をさらに増やすと共に他のパラメータにも対応させることでより汎用的に活用することの出来るものとしてほしい。

## 謝辞

本研究では、実測と CFD に関して東京理科大学 高瀬幸造氏(講師)から、AI の技術に関して株式会社フォトラクション 菊池光貴氏から知識や助言を数多く頂いた。ここに感謝の意を表します。

## 注

\*1 google earth (最終閲覧日: 2020/09/20)

## [参考文献]

- 1) 加藤 優輝: 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, 2017
- 2) 田中 英之: 畳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, 2019
- 3) 周 琦: 深層学習による室内気流予測手法の開発(その 1)二次元等温流れの再現結果に関する検討, 日本建築学会大会学術講演梗概集, 2019
- 4) 周 琦: 深層学習による室内気流予測手法の開発(その 3)二次元等温流れ予測の実現, 日本建築学会大会学術講演梗概集, 2020

5) pix2pix-GitHub (最終閲覧日: 2020年9月19日)

<https://github.com/tdeboissiere/DeepLearningImplementations/tree/master/pix2pix>

6) Phillip Isola: Image-to-Image Translation with Conditional Adversarial Networks. CVPR, 2017

7) Mehdi Miza: Conditional Generative Adversarial Net. arXiv preprint arXiv:1411.1784, 2014.

8) Olaf Ronneberger: U-net: Convolutional networks for biomedical image segmentation. MICCAI 2015

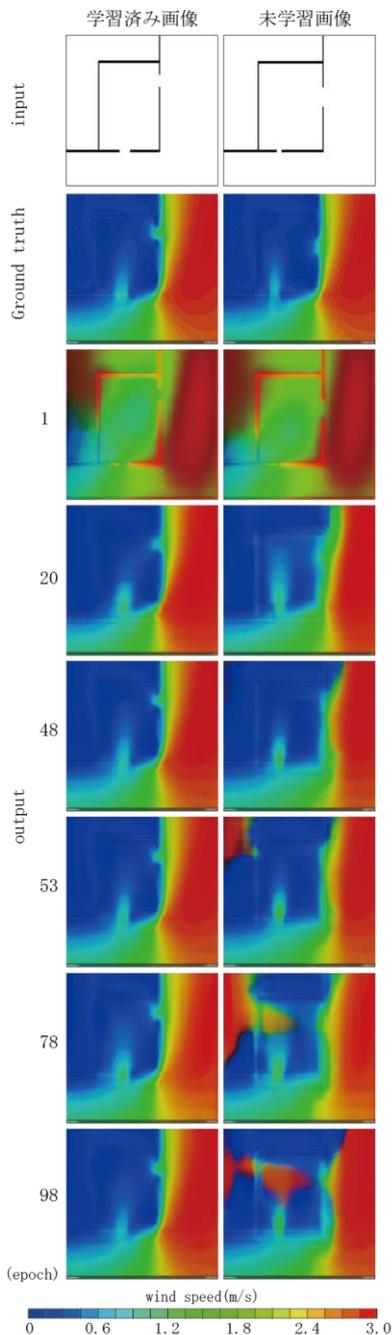


図8 部屋の位置に対する対応

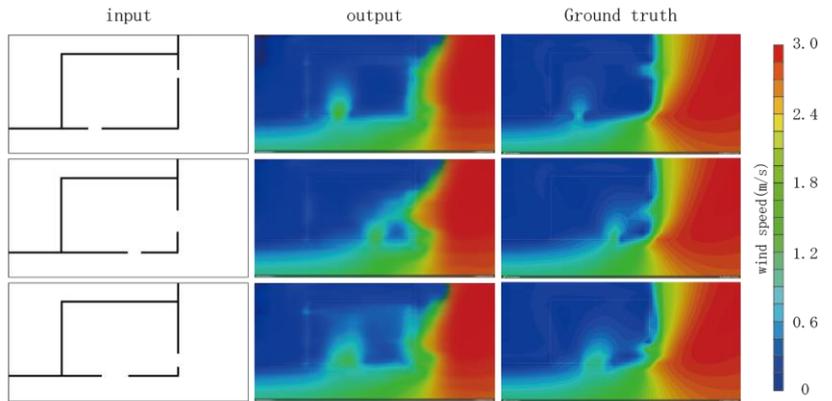


図9 窓幅と位置の変化に対する対応

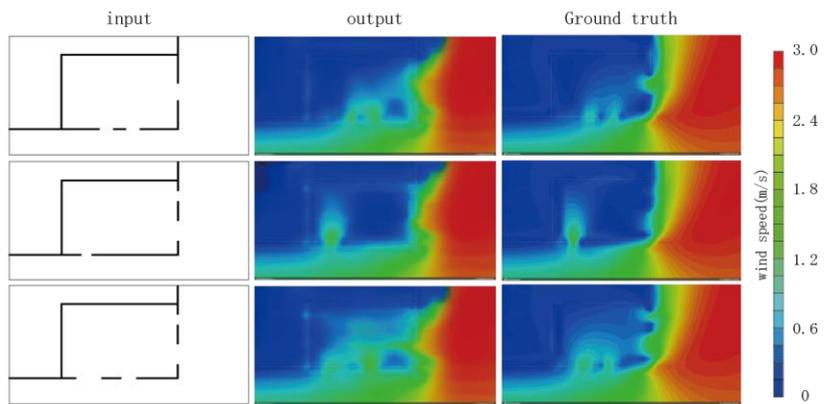


図10 窓数の変化に対する対応

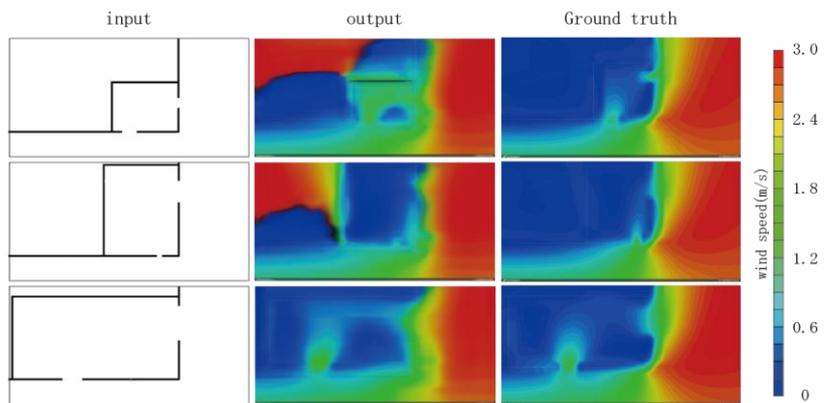


図11 部屋の大きさに対する対応

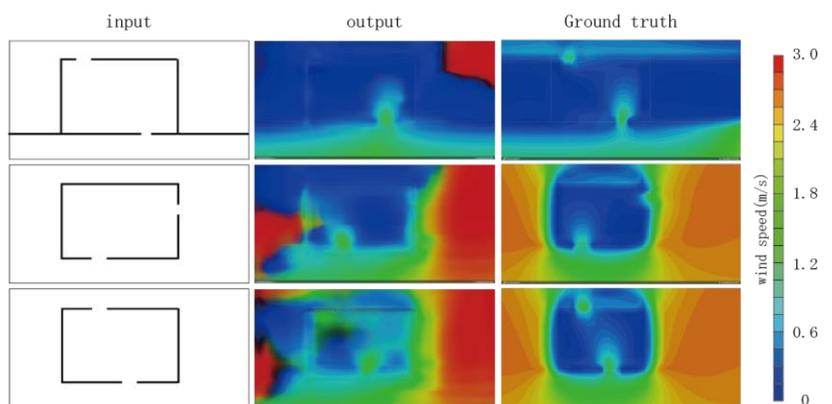


図12 部屋の位置に対する対応