

機械学習を用いた風環境予測精度の向上と防災技術への 応用

高木 洋平（横浜国立大学）

概要

大型台風のような強風環境下では、突風による建物表面での急激な圧力変化によって側壁の破損などの危険性があり、事前にその危険性を評価しておくことが望ましい。本研究では、そのような非定常な風環境に起因する建物表面でのピーク風圧を予測するために、数値流体解析 (CFD) と機械学習を融合させた推定モデルの構築を目指す。2020 年度は基礎的な検証として、1:1:2 の単体建物モデルをベースとして建物前面を 8 分割して網羅的に変更させた形状を作成し、非定常 LES 解析及び定常 RAS 解析を行なった。非定常 LES 解析の結果は風洞試験による実験結果とよく一致しており、機械学習の教師データ作成に LES を利用できることがわかった。また、LES 解析データを用いた平均風速・風圧およびピーク風速・風圧の算出を行い、CFD データから機械学習用データの生成が効率的に行えるようになった。

1 共同研究に関する情報

1.1 共同研究を実施した拠点名

東京大学 名古屋大学

1.2 共同研究分野

■超大規模数値計算系応用分野

1.3 参加研究者の役割分担

- 高木 洋平 (横浜国大): 流体解析・機械学習
- 大島 聡史 (名古屋大情報基盤センター): 高速化・性能評価・機械学習
- 今野 雅 (東京大学情報基盤センター): 流体解析・風環境予測システムの構築・高速化
- 下川辺 隆史 (東京大学情報基盤センター): 大規模計算・高速化
- 大塚 崇之 (日鉄エンジニアリング): 建築モデル構築

- 安田健太郎 (日鉄エンジニアリング): 建築モデル構築
- 境 昭裕 (横浜国大): 流体解析の実行、機械学習モデルの検証

2 研究の目的と意義

近年、大型台風が毎年発生し、台風通過地域での家屋や建物の破損・倒壊によって甚大な被害が発生している。台風という大スケールの流体運動についてはスーパーコンピュータによってその進路がある程度の範囲で数値的に予測可能となってきたが、台風上陸時の局地的な風環境の予測はその強い非定常性によって現状の計算機性能では困難な場合が多い。台風などの悪条件下での風環境予測は市街地に関しては風洞試験や数値流体解析 (Computational Fluid Dynamics, CFD) によって検討される場

合も多いが、市街地から離れた地域に建設される工場プラントや倉庫などに関しては従来の経験的な見積もりによって設計や施工がなされており、災害対策が不十分であることが多い。そこで、本研究では大型倉庫や工場などの産業用途建築物に対し、大型台風のような強風環境下での突風による屋根や壁面の破損危険性を予測するために、建物に働く瞬間的な最大風圧分布を予測するシステムを CFD と機械学習の融合によって構築することを目的としている。

CFD 技術の発展及び計算機性能の向上は著しく、定常的な流れ場の予測に関しては汎用的な CFD ソフトウェアを用いてデスクトップ PC などの身近なコンピュータで実現可能となっており、各種産業界において設計段階で日常的に行われるようになってきている。しかしながら、高速な非定常流れを解析するためには大規模計算機システムが必要であり、複雑な実機形状やマルチフィジクスな現象への CFD の適用は制限があるといえる。このような CFD による実流体现象再現のための計算機コストを削減する試みとして、機械学習を利用する研究開発が各産業分野で始まっている。CFD の利点は各座標点における速度・圧力データを時々刻々と出力・保持できることであり、大規模な学習データから何らかの予測モデルを構築する機械学習とは親和性が高い。しかしながら、現状での CFD と機械学習の融合研究の多くは、学習データの一部を伏せてそれをテストデータとして用いる”補間(内挿)”的な検討が多く、風環境における強風時の瞬間圧力の上昇などのような”外挿”を必要とする予測に対しては研究がほとんどなされていない。本研究では非定常な流れ場予測に適した Large-eddy Simulation (LES) と、定常な流れ場データセットを大規模に生成できる Reynolds Averaged Simulation (RAS) 解析を機械学習と組み合わせて利用し、

設計の初期段階で有用な風圧分布予測ツールとなる CFD-機械学習融合システムを開発することを目指しており、産業界に対する影響が極めて高い。

3 当拠点公募型研究として実施した意義

本研究課題では非定常 LES 解析による機械学習用教師データの作成と入力データとしての定常 RAS 解析を実施し、それらのデータを活用して風環境予測用の機械学習モデルを構築することを目標としている。機械学習用の教師データにはそのデータの量と質的なばらつきが要求され、ある程度大規模な流体解析をパラメトリックな条件で速やかに実施できることが好ましく、本研究で使用したオープンソースソフトウェアである OpenFOAM を東京大学情報基盤センターの Oakbridge-CX 及び名古屋大学情報基盤センターの「不老」にて複数ノードの大規模並列解析を実施できたことは研究進捗において有意義であった。また、名古屋大学情報基盤センターの「不老」は多様なサブシステムから構成されており、流体解析によって生成した教師データを用いて機械学習モデルを検討する際に、データの移行を気にせずに大規模流体解析の実行と機械学習モデルの検証を行うことができた。当拠点公募型研究では大規模流体解析の実行を行う研究者だけでなく、高速化や機械学習に対する知見を持つ各拠点研究者が参画しており、各計算機資源の有効活用や計算コードのチューニングに関して有意義な連携が行えた。

4 今年度の研究成果の詳細

本研究で対象とする建物モデルは、日本建築学会が提供している CFD ガイドライン(”都市の風環境予測のための CFD ガイドブッ

ク”, 2020) に含まれる単体建物モデル (1:1:2 角柱モデル) であり, 流体解析ソルバーとしては OpenFOAM v2006 の標準ソルバーの 1 つである単相流非定常解析ソルバー `pimpleFoam` を用いた. 本研究を実施開始する前段階では, 実際に使用される倉庫などの建物形状を再現し, 台風強風条件を模擬した境界条件の作成も視野に入れていたが, 風環境予測に機械学習を取り入れる取り組み, 特に非定常な流体現象に起因するピーク風圧の予測に関しては基礎的な検証が必要であるため, 精度・質のよい教師データが作成可能な単純形状の単体建物モデルを用いて本年度の課題は実施することにした.

4.1 1:1:2 単体建物周辺流れ LES 解析の流入境界条件の検討

本研究課題ではまずはじめに実際の非定常流れを再現可能な高精度な LES 解析をできることが必須となる. 一般に建物周りの非定常流れを解析する際には, 流入境界条件が計算結果精度に与える影響は非常に大きい. 性質の良い流入変動風を作成するためには, 解析領域とは別に上流部分にドライバー部分を設けて発達した乱流境界層を得ることが望ましいが, LES 解析をこのような計算負荷の高いドライバー部分も含めて多数行うことを考えると現実的ではない. そこで本研究では, OpenFOAM で利用できる Digital Filter と風洞実験の助走部分を再現した LES 解析結果を補完する方法について検討を行なった.

まず Digital Filter による人口流入変動風であるが, 時間平均値 (図 1 の黒線) については, 風洞実験結果 (図中の $\circ$ 印) とおおむね一致するが, 変動成分である乱流エネルギー (図 2 の黒線) については再現性が悪い結果となった. また, 領域分割により流入面が別々の領域になると, 変動風生成の負荷が高くなる欠点が見られた. 実験値をよく再現するためには助走区

間を長くしたり, 助走区間の床に壁関数を適用し, 粗度長を調整するなどのチューニングが必要であることもわかった.

一方の風洞実験の助走部分を再現した LES 解析結果を補完する方法では, 流入変動風として高品質であり, 助走部分を再現した LES 解析にコストがかかるが, 時間平均値および変動分について, 風洞実験結果とおおむね一致する結果が得られた (図 1-2 の赤線). よって, 今回の基礎研究では, 機械学習の教師データとなる LES 解析での変動分の予測精度が求められるので, こちらの流入風を採用することにした.




図 1 主流方向の平均風速の比較.




図 2 乱流エネルギーの比較.

4.2 LES・RAS 解析の設定ベイズ最適化

本研究課題にて割り当てられた計算機資源 (東京大学 Oakbridge-CX, 名古屋大学「不老」) を有効に活用するため, OpenFOAM で設定する計算パラメータについてベイズ最適化を行

なった。格子点数 300 万点 (建物辺 40 分割) の LES 解析を東京大学 Oakbrige-CX を用いて行い、以下に示すノード数毎にベイズ最適化し、ノード時間を最小化 (200 回試行) する最適化を行なった。

- ノード数: 1, 2, 4, 8(最適値), 16
- PPN(Process Per Node, ノードあたりのプロセス数): 56(初期値, 最適値), 54, 52
- 領域分割手法: scotch(初期値), kahip(最適値), multilevel
- 圧力の線型ソルバ: DIC-PCG(初期値), FDIC-PPCR(最適値), DIC-GAMG, DIC-PCG-GAMG 等
- 速度の線型ソルバ: symGaussSeidel(初期値, 最適値), DILU-PBiCG

上記の最適化によって、ノード時間は初期値に比べてノード時間は 1/1.84 となり、解析速度は 8 ノードでの初期値設定に比べて 1.22 倍高速化された。

一方 RAS 解析について、名古屋大学「不老」クラウドを用いて LES 解析と同様に設定パラメータのベイズ最適化を行なった。格子数 100 万点 (建物辺 20 分割) の RAS 解析に対して、以下に示すパラメータでベイズ最適化し、ノード時間を最小化 (500 回試行) する最適化を行なった。

- ノード数: 1(初期値), 2(最適値), 4, 8
- PPN(ノードあたりのプロセス数): 80(初期値, 最適値), 78, 76, 74, 72, 68, 64
- 領域分割手法: scotch(初期値), kahip, multiLevel(最適値)
- 圧力の線型ソルバ: DIC-PCG(初期値), DIC-PPCR(最適値), DIC-GAMG, DIC-PCG-GAMG 等
- 速度・乱流統計量の線型ソルバ:

symGaussSeidel(初期値), GaussSeidel, DILU-PBiCG(最適値)

上記の最適化によって、ノード時間は初期値に比べてノード時間は 1/1.12 となった。これらの LES・RAS 解析に対する設定パラメータのベイズ最適結果を用いて機械学習用の教師データ・入力データを作成することにした。

4.3 形状変更前の単体建物モデルを用いた LES 解析と RAS 解析の比較

本研究課題では建物の表面形状を変更した際に、ピーク風圧などの特性がどのように変化するかを機械学習によって予測することが最終目標であるが、その前に形状変更を行っていないベースとなる単体建物モデルに対して LES 解析と RAS 解析を実施し、その結果を実験値とともに比較して解析対象での流体力学的な特性が LES 解析でなければ再現できないことを確認した

図 3 に平均風速の比較を示す。LES 解析はほぼ風洞実験結果 (図中の ○) と一致するが、RAS 解析では建物後流域で実験値から少し乖離することがわかる。

乱流統計量の一つである乱流エネルギーの比較を図 4 に示す。LES 解析はほぼ実験値と一致するが、RAS 解析では建物前方で風洞実験結果 (図中の ○) に比べて過大に予測する一方、建物上方、建物後流で実験値に比べかなり過小予測していることがわかり、RAS 解析のみでは風環境予測の精度が不十分である。

4.4 LES 解析データを用いた平均風速・風圧およびピーク風速・風圧の算出

気象庁における提供される風速データは 10 分間の平均値であるため、LES 解析においても実時間 10 分間相当の解析を行い、その区間での平均風速や、平均圧力を算出する必要がある。しかし、風洞実験や数値流体解析において




図3 平均風速の比較: (top) LES, (bottom) RAS.




図4 乱流エネルギーの比較: (top) LES, (bottom) RAS.

は、実時間 10 分間相当の 1 区間のみでは、平均値および速度や圧力のピーク値は安定しないため、通常は数区間でのアンサンブル平均を行うのが一般的である。本研究では、LES 解析結果を機械学習の教師データとするので、実時間 10 分間相当の 5~7 区間程度のアンサンブル平均を施した統計値を教師データとして用いる。さらに、最大瞬間風速値は 3 秒間平均値の最大値であるので、LES 解析で求まる風速について実時間 3 秒相当で移動平均した上で、実時間 10 分間相当の区間において最大値を求めるが、平均値と同様にアンサンブル平均を行う。また、ピーク風圧は通常 0.5~1 秒間の平均値に対するピーク値なので、LES 解析で求まる壁面での圧力について実時間 1 秒相当で移動平均した上で、実時間 10 分間相当の区間においてピーク値を求めるが、平均値と同様にアンサンブル平均を行う。

本研究の機械学習で入力とするデータセットは、建物表面の圧力といった 2 次元データのみではなく、表面近傍の風速や乱流統計量といった 3 次元データであり、サンプリング点が多い。そのため、LES 解析の時間刻み (5×10^{-5} 秒) 毎に、多くのサンプリングを行うと、サンプリング結果のファイルも巨大になり、かつ、ファイル I/O のため解析が非常に遅くなる。そこで、解析領域全体で解析している風速や圧力の移動平均を行ない、さらに 10 分毎にピーク値の分布を求め、場のデータとして出力する関数を作成した。これにより、機械学習のためのデータセットやサンプリング点が決定されていなくても、LES 解析を行うことが可能であり、解析で出力された実時間 10 分間での平均値やピーク値の場データから、任意の領域でのデータセットが取り出せるようになった。




図5 単体建物の形状変更.

4.5 LES 解析による単体建物に関する教師データの作成

図5に示すように、風上側の壁面を8面に分割し、各々の面が建物幅の1/10 (模型スケールで10 mm) の厚み分が張り出す形状変更を行なった。教師データは多いほうが望ましいので、全ての形状変更ケース (中心断面で鏡映対称となるケースを除いて全136ケース) について非定常LES解析を行った。また、機械学習の入力データとなる定常RAS解析についても全ケース実行した。

前述のピーク風圧について、LES解析の最大ピーク風圧係数 ($C_{\max}$)、最小ピーク風圧係数 ($C_{\min}$) を算出し、建物表面から第1セルでの乱流エネルギーを算出した。RAS解析での風圧係数 (C_{RAS}) を用いて、変更した建物形状でのLES解析とRAS解析の風圧係数の差 ($C_{\max} - C_{\text{RAS}}$, $C_{\min} - C_{\text{RAS}}$) の一例を図6及び図7) に、同じ形状での乱流エネルギーの分布を図8に示す。これらの統計量分布には何らかの相関があることが見て取れ、建物形状の変更に伴うピーク風圧の機械学習による予測には、建物形状や周囲平均流速・風圧の他に、乱流エネルギーなどの乱流統計量を使用することによって高精度なモデルを構築できると予想される。




図6 最大ピーク風圧係数のRAS解析との差.




図7 最小ピーク風圧係数のRAS解析との差.




図8 乱流エネルギー.

4.6 必要最低限な教師データ生成のためのCFD計算条件の設定

建物形状を変更して教師データを作成するためにはLES解析を実施する必要があるが、似たような風圧特性を示す形状については代表的なもののみとして計算ケースを減らすことが好ましい。RAS解析はLES解析に比べて低計算コストで複数ケースを速やかに実行できるため、形状変更を行なったRAS解析を実施してその解析結果をクラスタリングして性質が似通ったデータセットを判別することを試みた。

前述したように建物前面壁面を8分割して形状を張り出す場合、対称性を考慮すると136




図9 ウォード法による階層的クラスタリング。

ケースの形状変更が可能であるが、ここでの検討では任意の10ケースを選択してそのRAS解析データを用いた。選択した10ケースのRAS解析結果から建物前面パッチでの圧力分布をサンプリングし直し、クラスタリングを行なった。本解析では最も似ている組み合わせから順番にまとまりにしていく方法の階層的クラスタリングを採用しており、この手法では樹形図で関連を表わすことができる。今回クラスタリングするにあたり、建物前面128点の圧力を各サンプルが持つデータとした。クラスタリングの手法として、ウォード法、最短距離法、最長距離法(最遠隣法)、群平均法、重み付き平均法を用いて検討を行なった。各クラスタリング手法から、最短距離法を除いたすべてのケースで同様の4クラスターに分けられることがわかった。例えばウォード法を用いると、図9の樹形図が示すようにクラスタリングされる。

同じクラスターに分類される条件において建物前面壁での圧力分布を可視化すると(図は省略)、結果よりある程度形状と風圧に関係があることがわかり、おおむねクラスタリングの結果に従っていることが確認できた。よってこれらのクラスタリングによって、LES計算のための建物形状を選択して効率的に教師データを生成することが期待される。

5 今年度の進捗状況と今後の展望

本課題開始時の研究項目は以下の3項目であった。

1. 非定常 LES 解析による機械学習用教師データの作成
2. 風向を変化させたパラメトリックな定常 RAS 解析
3. 定常 RAS 解析データを入力として用いる機械学習予測モデルの構築

非定常 LES 解析については比較検証として実験値が入手できる単体建物形状へと解析対象を変更したが、実際の風環境を再現するために必要な流入境界条件や計算精度について十分な検証ができた。また各拠点の計算機資源を用いて100~200ケースのパラメトリックなLES解析であれば実施可能であり、十分な機械学習用教師データを作成できた。

風向を変化させたパラメトリックな定常 RAS 解析については、機械学習予測モデルの入力値として与えるものを風向から建物形状へと変更したために実施していないが、形状変更に対する定常 RAS 解析は非定常 LES 解析と同様に実施できているため機械学習に用いるデータセットの構築は完了できた。

定常 RAS 解析データを入力として用いる機械学習予測モデルの構築に関しては、今年度後半から検討を開始したが、成果として報告できる機械学習モデルの結果は得られていない。これは機械学習モデルの構築には、ある程度のばらつきを持った教師データの準備が必要であり、また CFD 解析の結果をそのまま機械学習モデルに組み入れることは難しく何かしらの前処理が必要であるため、研究実施スケジュールにおいて機械学習の本格的な検証が遅くなったことが原因の一つである。また、使用

した名古屋大学「不老」の Type I において、OpenFOAM の解析実施中に、MPI プロセスのメモリーリークによる異常ジョブ終了が多数発生した (2020 年 12 月)。これらはジョブを投入するユーザー側の問題ではなくシステム側の問題であり、MPI ライブラリの不具合があつて 2021 年 2 月のシステムアップデートで解消されたが、研究進捗に多大な影響があつた。

成果が期待される機械学習モデルの構築について未完であるが、有用な機械学習用教師データは今年度作成できたため、データを活用して今後引き続き検討を進める予定である。現在検討している機械学習モデルは以下の 2 段階の構成となっている。

1. 自己符号化器による次元圧縮
2. 畳み込みニューラルネットワークによるスカラー値の予測

自己符号化器 (Denoising Auto Encoder, DAE) は元のデータから特徴量を抽出してデータの次元数を作成するものである。DAE は図 10 に示すようにエンコード層とデコード層に分かれており、デコードされたデータが元の情報量に対して許容される損失量になるように各層を学習させ、削減可能な次元数を決定する。




図 10 自己符号化器。

機械学習の推定モデルにて入力値として用いる物体形状は 3 次元複雑形状であり、CAD 形式 (STL 形式) で与えられる。また、本研究では RAS 解析による建物周辺の平均風速などの情報も入力値として与えるが、平均風速は地面

からの距離 z に依存するので、建物を z 軸に沿って分割し、各 2 次元断面での値を推定モデルに受け渡す必要がある。物体形状、平均場の情報は CFD 解析で用いているものは非常にデータ数が多いので、学習がうまくいかないおそれがあり、この自己符号化器によって次元圧縮して学習データの入力値に用いる。

開発モデルの後半部分として、入力データとして DAE によって次元圧縮されたデータを与えて機械学習の推定モデルを構築するが、出力値には任意性があり、目的に応じた推定ネットワークを構築する必要がある。建物周りの風環境予測の基礎的検討として、建物表面でのピーク風圧係数のようなスカラー値を一意に推定するモデルならば、図 11 に示すような畳み込みニューラルネットワーク (Convolutional Neural Network, CNN) が実績があるため現在検討を進めている。




図 11 スカラー値の推定ネットワーク。

6 研究業績一覧（発表予定も含む）

国内会議発表（査読なし）

- 今野雅, ‘名古屋大学スーパーコンピュータ不老の OpenFOAM ベンチマークテスト’, 第 1 回スーパーコンピュータ「不老」ユーザー会, 31 August, 2020.
- 大島聡史, 今野雅, ‘スーパーコンピュータ「不老」における OpenFOAM の性能評価’, オープン CAE・FrontISTR 合同シンポジウム 2020, D-5, 5 December, 2020.