

jh241005

大規模数値解析と機械学習を用いた軸流ファン騒音のデータ駆動解析

立川智章（東京理科大学）

概要

本研究では軸流ファンの騒音低減に資する流れ構造の理解を目的として、深層学習による流れ構造の可視化手法の検討を行った。軸流ファンへの適用に先立ち、可視化手法の有効性を検証するために基礎的な流体問題として円柱周り流れを対象とした。近傍場から遠方場の変動を予測する深層学習モデルを構築した上で、Grad-CAM および Integrated Gradients (IG) を適用し有効性の検証を行った。その結果、両手法とも単に変動の大きい領域に反応しているわけではなく、円柱両側の剥離線断層付近や後流の渦構造に対して顕著に反応を示すことが確認された。Grad-CAM は局所的な強い反応を示す一方で、解像度が低く反応領域がぼやける傾向が見られた。一方、IG は不要な寄与を抑制しつつ高解像度な可視化を実現し、より細かな構造を捉えている様子が確認された。得られた結果はモデルがターゲット予測において物理的に意味のある流れ構造に着目していることを示唆している。

1. 共同研究に関する情報

(1) 共同利用・共同研究を実施している拠点名

mdx

(2) 課題分野

データ科学・データ利活用課題分野

(3) 参加研究者一覧と役割分担

- ・立川智章 課題代表、データ解析
- ・青野光 数値計算
- ・大林航 データ解析

2. 研究の目的と意義

騒音問題は多くの場所で発生し、その低減は社会課題として広く認識されている。小型軸流ファンは情報機器や自動車など幅広い分野で利用されており、近年では小型化や集積化に伴い、冷却性能を維持しながら騒音を低減することが重要な課題となっている。ファンの駆動回転数を下げることで空力音を低減することはできるが、冷却性能も同時に

低下するため、単純な駆動制御では解決できない。このため、ファンの複雑な流れ現象の理解に基づく設計指針の創出が必要である。

申請者らはこれまで Large Eddy Simulation を用いて軸流ファンの大規模数値解析を実施し、ファンの主要素であるインペラ、ボス、ケーシング周りの流れ場とその干渉に注目した解析を行ってきた。従来の可視化手法による解析に加え、固有ベクトルによる線形変換によって時系列データの次元縮約を行う固有直交分解 (Proper Orthogonal Decomposition, POD) や多次元の時系列データから時空間の特徴的な構造を抽出する動的モード分解 (Dynamic Mode Decomposition, DMD) を利用した解析、疎性と畳み込みを利用するニューラルネットワークである疎性畳み込み自己符号化器 (Sparse Convolutional Auto Encoder, SCAE) を用いた解析を行い、流れ場構造の抽出と騒音源の特定も試みてきた。一連の流れ場の詳細解析から得られた知見により、ファ

ンの流れ場構造の特徴が分かってきているものの、各データ分析手法には一長一短がある。例えば、POD や DMD は時間方向の縮約を目指した手法であるためどこから音が生じているかといった知見を得ること（音源位置の同定）が難しく、ニューラルネットワーク（SCAE）の結果は人が解釈することは容易でない場合が多い。さらに、分析には多数の試行錯誤と場合によっては数値解析と同程度の時間を要する。そのため、流れ場の特徴抽出や騒音源同定につながる新たなデータ分析手法が必要である。

そこで本研究では、軸流ファン周りの大規模数値解析により得られた大規模データに対して、画像認識や画像処理分野で用いられているデータ分析手法を適用し、流れを支配する流れ構造を明らかにすることを目的とする。データ分析手法としては、画像認識の分野においてモデルの分類結果の根拠の可視化に用いられる Gradient-weighted Class Activation Mapping (Grad-CAM) や Integrated Gradients (IG) に注目し、流体問題への適用を試みる。Grad-CAM は畳み込み演算を用いた教師あり学習であるため正解データを用意することが必要であるためそのままでは適用できない。そのため流れ場を近傍場と遠方場に分け、遠方場の点データを正解データとすることを試みる。このような前処理を行うことによって Grad-CAM や IG を適用することが可能となり、観測点で観測される騒音（圧力変動）がどこから発生したか（重要な領域）どうかを可視化することができる。

本研究には二つの重要な意義がある。1 つ目は、低レイノルズ数領域における現象理解への貢献である。この領域では、ドローンなどの無人小型飛行体の飛行特性や流れ制御が注目されているが、非線形現象が多く、未解明の部分が多い。対象とする小型軸流ファンのレイノルズ数もこの範囲となる。

2 つ目は、他分野の手法を適用することにより新たな知見を促進する点にある。Grad-CAM や IG といった手法を適用することで、流れ構造の重要な部分を可視化し、新たな視点から流体問題における重要な流れ構造に関する新しい知見を得ることが期待される。

3. 当拠点の公募型共同研究として実施した意義

本公募型共同研究では、非 HPCI 資源においても汎用 (CPU) ノードに加え、演算加速 (GPU) ノードを利用することができる。昨今の GPU の価格高騰は研究室の負担が大きいため、NVIDIA A100 を利用することが出来ることで大規模データを用いた機械学習モデルの学習が効率的に実施することが可能となった。計算資源の制約により困難であった解析を進めることができたことの意義は大きいと考えられる。

また、mdx は仮想化された環境を構築することができるため、柔軟なソフトウェア環境を構築することが容易であり、開発からシミュレーション実験まで研究プロセス全体の効率化に寄与した点も大きい。場合によっては依存関係が複雑となるライブラリやツールも導入が容易であり、再現性の高い計算環境を短時間で整備することができることの意義も大きいと考えられる。

4. 前年度までに得られた研究成果の概要

該当なし

5. 今年度の研究成果の詳細

本年度は、軸流ファンの適用に先立ち、基礎的な流体問題を対象に Grad-CAM, IG を用いた分析手法を適用し、有効性の検証を行った。いずれの分析手法も仮想環境上において Python および PyTorch を用いて実装した。

まず、流れ場を予測する深層学習 (CNN) モデル F_{CNN} を構築する。流れ場は近傍場とそこから離れた位置にある遠方場に分割される。

F_{CNN} は近傍場の情報から情報の伝搬過程を考慮し遠方場の挙動を推定するモデルである。システム内を伝播する情報を捉えるために、ある時刻 t から $t + T$ までの時間経過に伴う変動を考慮する。式 (1) に示すように、近傍場における物理量 $flow_{nearfield}$ を入力として、遠方場における物理量 $flow_{farpoint}$ の時間積分された変動量 $(\int_t^{t+T} (flow_{farpoint})^2 d\tau)$ を深層学習モデル F_{CNN} で予測する。

$$\int_t^{t+T} (flow_{farpoint})^2 d\tau \leftarrow F_{CNN}(flow_{nearfield}), \quad (1)$$

このモデルは分類問題として定式化され、入力データは事前に正規化される。時間積分された変動量があらかじめ定めた閾値より大きければラベル「1」、そうでなければラベル「0」が与えられる。学習の損失関数としては 2 値クロスエントロピーを用いる。

次に学習によって得られたモデルがどのような特徴に着目して予測を行っているのかを可視化するために、Grad-CAM や IG を適用し、モデルが着目している空間的領域を可視化し分析する。これによりモデルの予測精度だけでなく、モデルの判断根拠となる流れ場の重要領域を視覚的に理解することができる。学習から可視化・分析までの一連のプロセスを図 1 に示す。

流体問題としては、3 次元円柱周りの流れを対象とした。格子点数は円周方向、スパン方向、径方向について $970 \times 107 \times 961$ 点であり、スパン方向長さは 2π である。レイノルズ数 3900、マッハ数 0.2 とし、無次元時間刻み幅は 0.0005 とした。計算には圧縮性流体解析 solver LANS3D を用い、対流項および粘性項には 6 次精度コンパクト差分を、メトリクスおよびヤコビアンには 10 次精度コンパクト差分をそれぞれ適用した。時間積分には 2 次精度 ADI-SGS 陰解法を適用し、内部反復 (3 回) を組み込むことで時間精度を保持した。

図 2 に計算結果の平均壁面圧力係数、図 3 に後流側の円柱の中心位置での流れ方向平均速度の比較を示す。図より、過去の実験値と計算値と概ね一致していることが分かる。

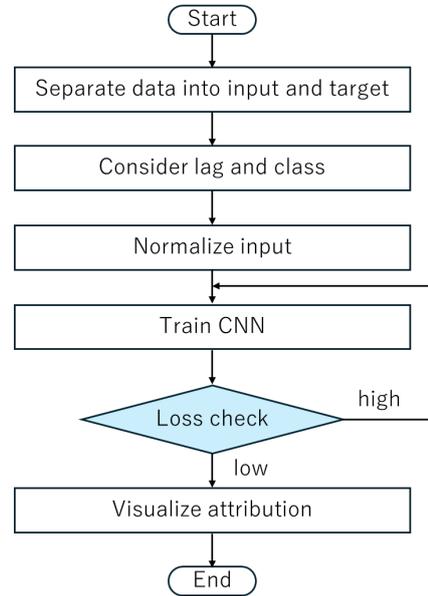


図 1 分析フローチャート

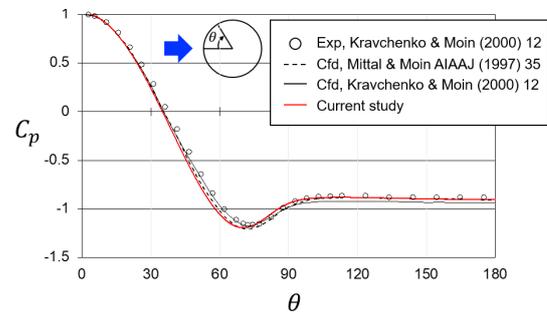


図 2 平均壁面圧力係数

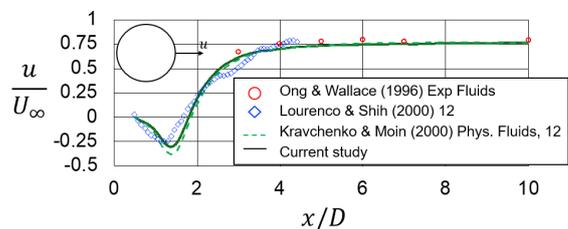


図 3 流れ方向平均速度

本研究では 3 次元流れ場および 3 次元流れ場に対しスパン方向平均を行った 2 次元流れ場の両方を解析対象とした。図 4 に 2 次元円柱周り流れ場の入力とターゲット位置を示す。

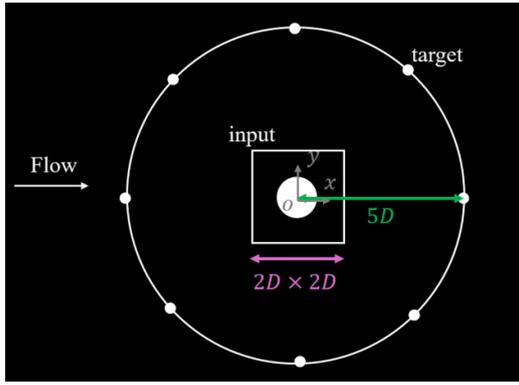


図 4 入力とターゲット位置

図に示すように D を円柱直径とし，入力となる近傍場は $2D \times 2D$ の矩形領域を 224×224 に離散化したものとし，ターゲットとなる遠方場は図中の黒丸で表す $5D$ 離れた後流位置周方向に 8 点と設定した．元の 3 次元流れ場周りの流れ場に対しては，近傍場の矩形領域を $224 \times 224 \times 224$ とし，ターゲットは円柱スパン方向中央断面に同様に設定した．ネットワークには 2 次元，3 次元いずれの場合も VGG16 をベースにした畳み込みニューラルネットワークを用いる．それぞれ 2D-VGG16, 3D-VGG16 とする．入力データの形状や解像度は，VGG16 の標準的な入力形式に整合するように構成されている．学習および評価には 220 タイムステップ分のデータを用いた．

(a) Grad-CAM の適用結果 (2D)

Grad-CAM は，分類結果に対してどの領域が重要だったかを可視化する手法であり，CNN の畳み込み層の勾配情報を使う．具体的にはまず，最終畳み込み層 A^k に対してクラス c の予測スコア y^c の勾配を計算し，それを空間全体 Z で平均することで α_k^c を求める． α_k^c はクラス c に対してマップ k の重要度を表している．

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (2)$$

最終的に重み付きのマップを ReLU 関数を通して合成することで根拠マップ $L_{Grad-CAM}^c$ が得られる．

$$L_{Grad-CAM}^c = \text{ReLU} \left(\sum_k \alpha_k^c A^k \right) \quad (3)$$

図 5 にターゲットを円柱後流位置 ($x=5.0D$) とし，十分予測誤差が収束した 2D-VGG16 に対して Grad-CAM を適用した結果を示す．図は密度 ρ への適用結果である．図の左側は遠方領域を含んだ円柱周り全体，右側に円柱近傍で計算される寄与を白く描画している．寄与 (Attribution) の分布は 0 から 1 に正規化されており，最小値 0 を黒，最大値 1 を白としている．図より単に変動が大きいところに反応しているわけではなく，円柱両側の剥離線断層付近および渦構造に白く反応していることが分かる．

寄与の反応領域がぼやけてしまった理由としては，畳み込みニューラルネットワークを使っているため，畳み込みを繰り返すほどに特徴マップの解像度が小さくなってしまふことが挙げられる．図 6 に各層における寄与マップの可視化結果を示す．左から入力に近い層で右に行くほど畳み込みが行われていく．図より，最も入力に近い層では寄与は前縁のよどみ点や後流の低速領域に全体に反応しているが，畳み込みが行われるにつれて，後流の局所的な流れ場に反応していることがわかる．このことは遠方場の流れの変動を生む近傍場内での重要領域が，剥離点や剥離せん断層であることを示唆している．円柱後流の変動がこれらから影響を受けることは自明であるが，Grad-CAM で可視化された

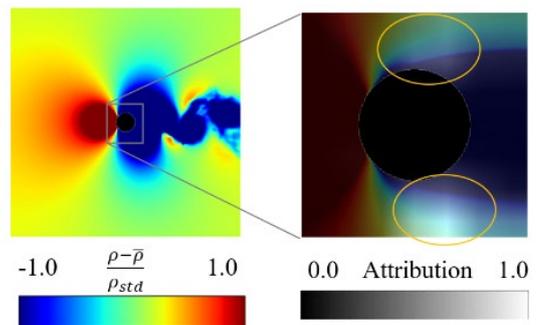


図 5 Grad-CAM の適用結果

重要な領域が、流体力学の既存の知見と矛盾しないことが確認された。本結果は 2024 年度の流体力学会年会で発表済である。

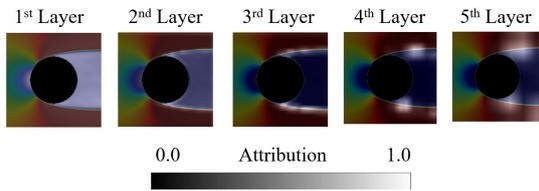


図 6 各層における寄与マップ

(b) IG の適用結果 (2D)

Integrated Gradients (IG) は、勾配の不変性と感度を活用して、入力されたデータの特徴の重要度を可視化する手法である。深層学習ネットワークを関数 $F: \mathbb{R}^n \rightarrow [0,1]$ とし、入力データを $x \in \mathbb{R}^n$ 、ベースライン入力を $x' \in \mathbb{R}^n$ と定義する。ベースライン入力 x' は、寄与が計算されない位置において予測対象が存在しないことを表すためのデータであり、本研究ではゼロベクトルとする。これにより、反応すべきでないところへの寄与の反応を抑えることができる。 \mathbb{R}^n 内における x' から x への直線状のパスの全ての点で、予測ターゲットに対する入力に関する勾配を計算し、式 (4) のように勾配を足し合わせることで Integrated Gradients が得られる。

$$\text{IntegratedGrads}_i(x)$$

$$= (x_i - x'_i) \int_{\alpha=0}^1 \frac{\partial F(x' + \alpha(x - x'))}{\partial x_i} d\alpha \quad (4)$$

ここで i は入力データの次元で、 α はベースライン入力から現在の入力までの経路積分の積分変数である。Grad-CAM との大きな違いの一つとして、IG は入力データと同じ解像度の可視化結果を出力する点が挙げられる。

図 7 に円柱後流位置 ($x=5.0D$) に対する 2D-VGG16 に対して IG を速度 u に適用した結果を示す。比較のために Grad-CAM も表示している。IG の結果も単に変動が大きなところに

反応しているわけではないことがわかる。Grad-CAM は解像度が低くなるのが原因でぼやけてしまっているが、IG は Grad-CAM の結果と比べてより詳細な分布が得られていることが確認できる。IG はベースライン入力を考慮することにより、反応すべきでない部分への寄与が抑制されるため、より細かな部分に反応が見られる。橙色で囲んだ部分に注目すると IG では円柱周りで速度勾配が切り替わる部分に反応が見られることがわかる。このことは、遠方場の変動を生む近傍場内での寄与が剥離点と剥離せん断層に基づいていることが示唆される。流れが剥離してカルマン渦が発生することを考えると、学習によって得られたモデルが反応している点に注目することで、物理的な知見との関連を見出すことが可能だと考えられる。特に、剥離点や剥離せん断層といった領域にモデルが高い感度を示すことは、ターゲットとした遠方場が近傍場のどのような構造に起因しているかを推測する手がかりとなりうると考えられる。本結果は 2024 年度の数値流体力学シンポジウムで発表済である。

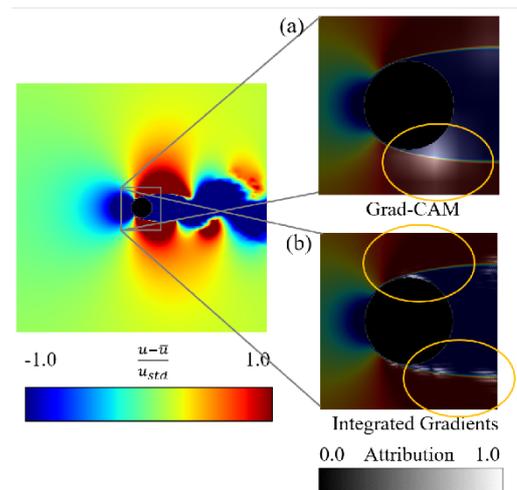


図 7 Grad-CAM と IG の適用結果

(c) Grad-CAM と IG の適用結果 (3D)

3D-VGG16 に対して Grad-CAM および IG を適用した結果は、現在詳細な分析を行って

るところである。図 8 は、スパン方向中央断面における円柱後流位置に対する 3D-VGG16 に Grad-CAM 及び IG を速度 u に適用した結果である。Grad-CAM および IG いずれにおいても、円柱後方の渦構造が発達している領域に反応が広く分布している様子が確認できる。これは、ネットワークのターゲット予測において、流れの変動が大きく非定常性の高い領域がモデルにとって重要であることを示唆している。一方で、可視化結果を詳細に比較すると、Grad-CAM と IG はそれぞれ異なる領域に反応していることがわかる。この違いは、Grad-CAM が畳み込み層に基づくため空間的な解像度が制限されるのに対し、IG は勾配情報を積分することでより細かな構造に反応できる点に起因すると考えられる。

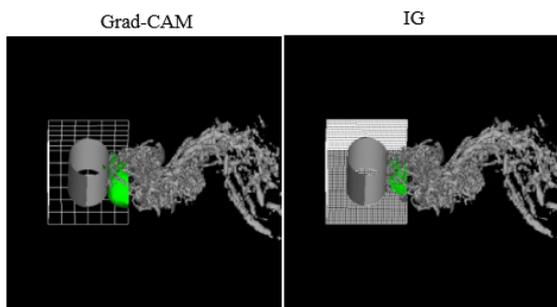


図 8 Grad-CAM と IG の適用結果

6. 進捗状況の自己評価と今後の展望

本年度は、軸流ファン騒音の解析に向けた入れた分析手法の検討として、円柱周り流れを対象に深層学習モデルを構築し、Grad-CAM および Integrated Gradients (IG) を適用することで、モデルの判断根拠の可視化と物理的整合性の検証を行った。スパン方向平均した 2 次元解析では、両手法ともに円柱後流の剥離点や渦構造といった非定常な領域に対して強く反応を示すことが確認された。得られた結果はモデルがターゲット予測において物理的に意味のある流れ構造に着目していることを示唆しており、従来手法では捉えることが難しかった構造を Grad-CAM や IG といったデータ駆動型の可視化技術が補完で

きる可能性が示唆されたと考えられる。3 次元円柱周りの分析が途中であることと、軸流ファンへの適用が次年度以降となることから、当初の全体目標には一部未到達の部分もあるが、本年度において基礎的な枠組みの構築と手法の有効性の検証を着実に進め、国内学会で発表することが出来た点で、意義のある成果が得られたと考えている。現在分析を進めている 3 次元円柱周りの結果については 2 次元解析の結果と併せて学術論文としてまとめているところである。

今後は、3 次元流れに対する解析をさらに進めるとともに、軸流ファン騒音解析への適用も進め、より複雑な流れ場に対する解釈可能な機械学習の枠組みを発展させる予定である。また、得られた可視化結果を従来の POD や DMD による結果と比較し、物理量との定量的な対応関係を検証することで、流体现象の理解に資する新たな知見の獲得を目指す。

※7. 研究業績はウェブ入力です