

深層学習を用いた 2 次元軸受空洞内の流体流れの低次モデリング

Reduced Order Modeling of Fluid Simulation in Bearing-like 2D Toroidal Cavity using Deep Learning

日本精工（株） （正）*楠崎 晃司 （正）*野田 隆史

Koji Kususaki*, Takashi Noda*,

*NSK Ltd.,

1. はじめに

数値流体力学（Computational Fluid Dynamics, CFD）は、機械設計、環境工学、生体工学など多岐にわたる分野において現象理解や設計最適化に活用されており、軸受設計においては潤滑油やグリースの挙動理解、形状最適化などに広く用いられている^{1,2)}。しかし、軸受内部で生じるような複雑な流れ場の解析には多大な計算時間を要するため、繰り返し計算を基本とする最適化問題との相性は一般的に良くない。このような計算負荷に起因する課題を解決する手法として、深層学習（Deep Learning, DL）技術を用いた流体解析の高速化が近年注目されている^{3,4)}。本研究では、Pantらが提案した深層学習ベース低次元化モデル（Deep Learning - Reduced Order Modelling, DL-ROM）フレームワーク³⁾を軸受内部流れの予測に適用し、2次元軸受空洞内で生じる流れ場（渦度）の予測を高速化した事例について報告する。

2. 計算手法

本研究で採用した DL-ROM フレームワーク³⁾は、深層学習を活用して流体解析を高速化する手法である。これは、高次元の流体場データを深層学習によって低次元の潜在空間で表現し、その空間で時間発展を予測するものである。このアプローチは非侵襲型（non-intrusive）であり、既存の CFD ソフトウェアの内部実装を変更する必要がない。したがって、CFD ソルバーをブラックボックスとして扱い、その出力データのみを用いてモデルの構築が可能である。DL-ROM フレームワークでは、時系列を考慮した 3 次元的なデータ構造（空間 2 次元 + 時間 1 次元）を 3D U-Net アーキテクチャによって学習させる。具体的には、3D エンコーダが流体空間をダウンサンプリングして高次の特徴を抽出し、それによって圧縮された特徴およびその時間発展を、3D デコーダが復元する。このエンコード・デコードの一連の処理が「U」の形をしていることから、このネットワーク構造は U-Net と呼称される。DL-ROM の学習・演算の流れは以下のとおりである。まず計算コストの高い CFD 解析を事前に行い、その結果として得られる流体場データの収集を行う。DL-ROM にはモデル構築時に乱数による重みパラメータを与え、数ステップの入力から次の 1 ステップの予測を行う枠組みを用意しておく。CFD の時系列流体場データを用いて、DL-ROM が予測する次の時間ステップの流体場と実際の次のステップの流体場との差分を計算し、それが最小となるように重みパラメータを調整、すなわち学習をしていく。一度学習が完了すれば、初期の数ステップを CFD から与えることで、それ以降は DL-ROM による予測、すなわち CFD 解析の代用となり得る高速な演算が可能となる。

3. 計算条件

本研究では、軸受内部の空間を模した 2 次元回転系閉鎖流体領域における渦度の時間発展を対象とした。軸受は玉が 6 つあり、外輪が固定され、内輪が自転し、玉が自転および公転している条件を想定した。これをもとに CFD に与えた境界条件は以下の通りである：流体領域は回転体 1 ピッチ分を周期境界として設定し、扇状の 1/6 カットモデルとして作成した。空間内の座標は極座標表示により、位相角 θ と半径 r の 2 次元円筒領域として与えた。壁面すべてにスリップがない条件とした。Figure 1 における inner 側には反時計回りに表面速度が与えられ、外径側は静止している。レイノルズ数は 400 である。玉の公転速度は inner の表面速度の 1/2 であり、自転速度は inner 側、outer 側それぞれで壁面との速度差が 0 になるように設定した。これらの条件下で、商用 CFD ソフトを用いて 1000 ステップの渦度場の時間発展データを計算した。境界内部の渦度については、0 埋めで処理をした。そのうち、800 ステップを学習データ、200 ステップを評価データとし DL-ROM の重みパラメータの調整を行った。具体的には、10 ステップの入力による次のステップの予測が CFD の結果と一致するよう、790 条件をもとに学習を行い、学習では用いなかった 190 条件で性能評価を行うサイクルを、精度の更新がなくなるまで継続した。学習にはおよそ 10 時間、イテレーションでおよそ 100 回を要した。

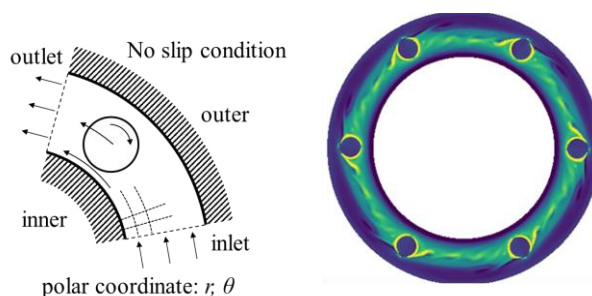


Fig. 1 Calculated area and vortex result of CFD




Fig. 2 CFD vs. AI prediction (time step=35)




Fig. 3 MSE increment across time steps

4. 結果

渦度の時間発展結果に基づき DL-ROM による予測精度の定量評価を行った．時間発展の手順は、まず 10 ステップ分の流体場データ（学習に未使用）を初期値として与え、11 ステップ目を DL-ROM に予測させる．続いてステップをひとつ進めて 2~11 ステップの結果から 12 ステップ目を予測させる、というサイクルを 25 回繰り返し、DL-ROM に 11~35 ステップ目の渦度を予測させた．CFD による渦度の解析結果と DL-ROM を用いた予測値（35 ステップ目）の比較を Fig. 2 に示す．転動体後方で生じる渦が DL-ROM においても解像できていること、また破線上での渦度プロファイル（Fig. 2 右）が良好に一致していることが見て取れる．このことから DL-ROM は CFD と同様の計算結果を再現可能であることが分かった．また各ステップにおける予測精度を式（1）により評価した．ここでは渦度 Ω の計算値（ Ω_{CFD} ）と予測値（ Ω_{pred} ）の一致度を測るため、以下の平均自乗誤差（Mean Squared Error, MSE）を用いた．

$$MSE = \frac{1}{\text{Var}(\Omega_{CFD})} \frac{1}{N} \sum_{i=1}^N (\Omega_{CFD,i} - \Omega_{pred,i})^2 \quad (1)$$

ここで Var は渦度の分散を表す演算子、 N は流体領域の格子点数である．ステップごとの MSE の変化（Fig. 3）を見てわかる通り、DL-ROM の予測誤差は時間発展と共に増大した一方で、1 ステップ当たりの計算時間は CFD の約 260 分の 1 に短縮される結果となった．

5. 考察

DL-ROM が CFD の結果を再現できた理由は、3D U-Net が軸受空洞内の渦度場の空間的・時間的特徴を効果的に捉えることができたと推察される．前述の通り、予測精度に改善の余地が残された一方で、260 倍程度の高速化は潤滑設計パラメタの最適化の実現など、従来計算コストが制約になっていた応用分野への適用に期待を抱かせるものであった．なお、今回の検証において精度が悪化していった原因は、DL-ROM の入出力に伴う演算において誤差伝播（Error Propagation）が起こったためと推察される．

6. まとめ

本研究では、Pant らが提案した DL-ROM フレームワークを軸受内部流れの予測に適用し、2 次元軸受空洞内で生じる流れ場（渦度）の予測に適用し、計算高速化の可能性を示唆した．今後は気液混相、3 次元空間への拡張、様々なレイノルズ数といった複雑な条件への適用を検討している．

文献

- 1) T. Noda, K. Shibasaki, S. Miyata, M. Taniguchi: X-ray CT Imaging of Grease Behavior in Ball Bearing and Numerical Validation of Multi-Phase Flows Simulation, *Tribology Online*, 15, 1 (2020) 36.
- 2) Wang, X. L., Zhu, K. Q.: Numerical analysis of journal bearings lubricated with micropolar fluids including thermal and cavitating effects, *Tribology International*, 39, 3 (2006) 227.
- 3) Pant, P., et al.: Deep Learning-Based Reduced Order Modeling for Fluid Dynamics, *Journal of Computational Physics*, (2020)
- 4) Raissi, M., Perdikaris, P., Karniadakis, G. E.: Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, *Journal of Computational Physics*, 378 (2019) 686.
- 5) Xiao, D., Yang, P., Fang, F., Xiang, J., Pain, C. C., Navon, I. M.: Non-intrusive reduced order modelling of fluid-structure interactions, *Computer Methods in Applied Mechanics and Engineering*, 303 (2016) 35.