

キャビテーション乱流の CFD データベースを用いた データ駆動型キャビテーションモデルの開発に関する研究

岡林 希依
大阪大学 大学院工学研究科

1. はじめに

近年、数値流体力学（Computational Fluid Dynamics; CFD）の分野において、畳み込みニューラルネットワーク（convolutional neural networks; CNN. 以下、ニューラルネットワークを NN と略する）の画像認識機能を応用し、流れ場データを画像のピクセルデータと見なした教師あり学習の例が急増している。中でも、NN で従来の数理モデルを代替する、データ駆動型モデルが注目を集めている。また、近年の実験流体力学では、光学計測と画像処理を利用した計測法の発達により、センサ類から得られる点データだけでなく、流れ場全体や断面、物体表面などの二次元データを蓄積することができるため、このような計測データを CNN の学習データセットとして扱うことも可能になってきている。これらの手法はデータ駆動型モデルとしての側面の他にも、いわゆるデータ同化としての側面も持ち合わせており、計測データを援用することで、数理モデルによる現象のモデル化など CFD の不確定性を補正する役割が期待されている。

著者は、相変化を伴う気液二相流であるキャビテーション流れの数値シミュレーション研究 [1,2] の経験から、多様なキャビテーション現象とそれに付随する課題を統一的に表せる数理モデルが開発されるには至っていないこと、先行するキャビテーション流れの実験的研究によって高精度な計測データが多数取得されていることに着目した。そして、モデル開発のためのブレークスルーとして、NN が表す非線形関数により数理モデルよりも柔軟な表現が可能であり、かつ計測

データを用いることによるデータ同化の側面も持ち合わせたデータ駆動型キャビテーションモデルを開発するという着想に至った。本稿では、計測データを学習させる前の準備段階として、CFD データベースを学習データとしたデータ駆動型キャビテーションモデルの枠組みについて紹介する。また、その研究要素として、計測データを想定した二次元場から三次元場への拡張についても紹介する。

2. CFD データを学習させたデータ駆動型キャビテーションモデル

図 1 に CFD データ（数理モデルで計算した）を学習させた NN に基づくデータ駆動型キャビテーションモデルの概念図を示す。これは現ステップの気液密度、速度、圧力の各流れ場 $\rho_m^{(n)}, \mathbf{u}^{(n)}, p^{(n)}$ を入力とし、次ステップの気液密度場 $\rho_m^{(n+1)}$ を予測する回帰モデルの構築に帰着する。学習データセットは、数理モデルで計算した翼周りのキャビテーション流れであり、その中でもキャビティの初生、シートキャビティの発達、クラウドキャビティの放出などの一連の現象を周期的に繰り返す非定常性が比較的強い条件を採用する。図 1 の A priori テストにおける学習モードでは上記の二周期分のデータ（3000 枚の瞬時場）、テストモードでは約半周期分のデータ（1000 枚の瞬時場）を用いる。NN として、U-Net[3] を用いる。学習後、NN を流れのシミュレーションコードに実装した、図 1 の A posteriori テストにおいて、図 2 のように数理モデルとほぼ同じ流れ場が予測できた[4]。しかしながら、現時点では数周期のキャ

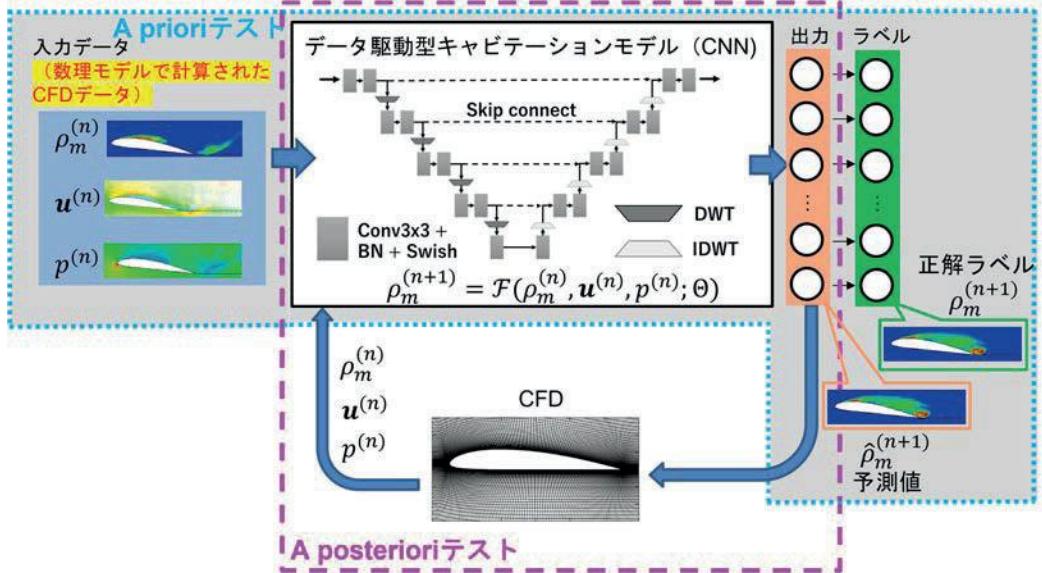
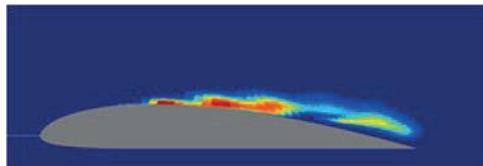
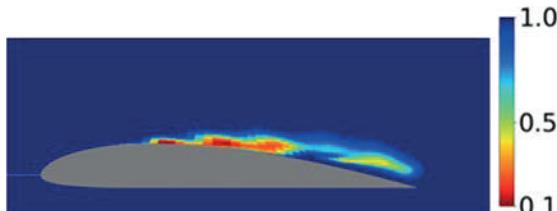


図 1 : CFD データを学習するデータ駆動型キャビテーションモデルの概念図



(a) データ駆動型モデル



(b) 数理モデル[4]

図 2 : 各モデルでの気液密度場

ビテーション現象をシミュレートしたのち計算が不安定化している。発散に至ったきっかけの計算セルでは、リエントラントジェットと称する翼後縁付近での逆流現象や、クラウドキャビティと翼端渦キャビティの干渉など、非定常性の強い現象が起こっており、NN がこれらの急激な変化を示す時間微分項を高精度で予測できていないことが不安定化の原因であることがわかっている。非定常現象の再現が困難であるのは、数理モデルによるシミュレーションにおいても共通している。時間微分項の誤差は翼端など非常に小さい領域で局所的に生じるため、そのような誤差が NN

で最小化すべき損失関数に反映されるような工夫が必要であることが示唆される。

3. 超解像 NN を用いた二次元→三次元データへの拡張

粒子画像流速計測 (PIV)、圧力センサ、高速度カメラなどの計測で得られる場は高々二次元（物体にフラッシュマウントされた圧力センサでは特に一次元しかない）であり、そのまま三次元流れの学習に持ち込むことができない。そこで、計測データを想定した二次元流れ場を入力し、CFD データを援用して三次元流れ場を出力する機械学習モデルを開発する。NN には超解像 NN[5]を用いる。超解像機械学習とは、低解像度画像から高解像度画像を出力するパターンを機械学習で予測するものであり、一種の補間技術に相当する。これを二次元場から三次元場への高次元化に応用することを考える。

図 3 に二次元の CFD データの物理量を入力として、三次元流れ場を推定する超解像 NN の概念図を示す[6]。学習データには迎角 8 度、キャビテーション数 σ （飽和蒸気圧の無次元数であり、 σ が大きいほどキャビテーションが発生しにくい）が 1.2 の翼周りのキャビテーション流れにおける速度場、圧力場、気液密度場を採用する。この条件

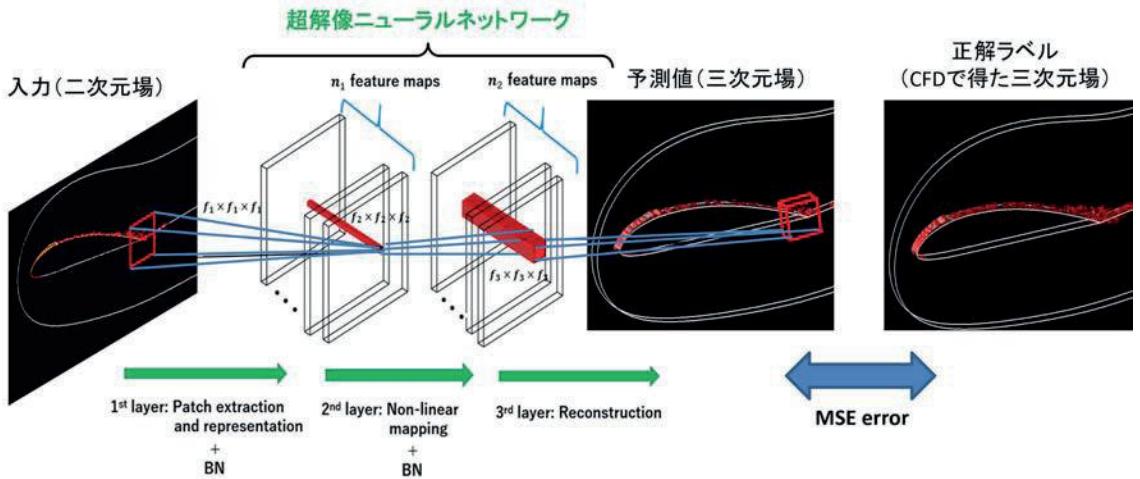


図 3 : 超解像ニューラルネットワークを用いた流れ場の高次元化の模式図[6]

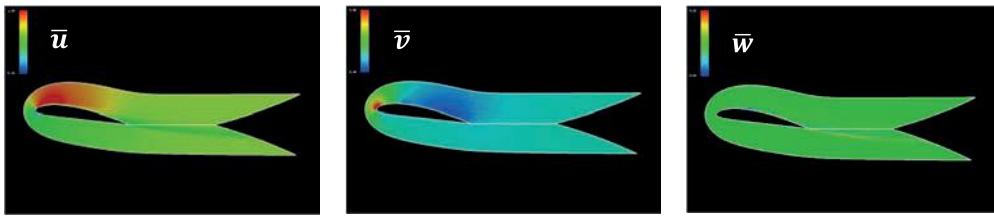
の流れ場は、シートキャビティ振動、クラウドキャビティの放出などの周期的で非定常なキャビテーション現象が起こる。この周期的な時系列の流れ場を約 2 周期分学習に用いる。物理量（速度三成分 u, v, w , 壓力、気液密度）ごとに NN を用意し、独立に学習させる。入力の二次元場としては、現時点では仮に教師ラベル三次元の CFD データの翼スパン方向断面を用いる。ただし、スパン方向速度成分 w は二次元場には存在しないため、 w を予測する NN の入力は、断面に沿う成分の一つである v を代わりに用いる。また、テストデータ（予測性能の評価に用いる、学習したものとは異なるデータ）として、迎角 8 度、 $\sigma=2.0$ の時系列の流れ場を約 1 周期分用いる。 $\sigma=2.0$ の場合は、シートキャビティが定在し、学習に用いた $\sigma=1.2$ よりも非定常性の小さい流れ場である。

図 4 に時間平均・スパン方向平均した速度のテストデータ（正解）と、予測値をそれぞれ示す。図 4 から、断面に沿う速度成分 u, v は定性的には妥当に予測できていることがわかる。しかしながら、二次元場には存在しない w は妥当ではない結果が得られている。図 3 の模式図では、予測値の三次元場において、下流の縦渦が再現されていないことが、速度のスパン方向成分が妥当でないことを示している。図 5 に時間平均・スパン方向平均した翼面上の圧力係数 (C_p) 分布を示す。キャ

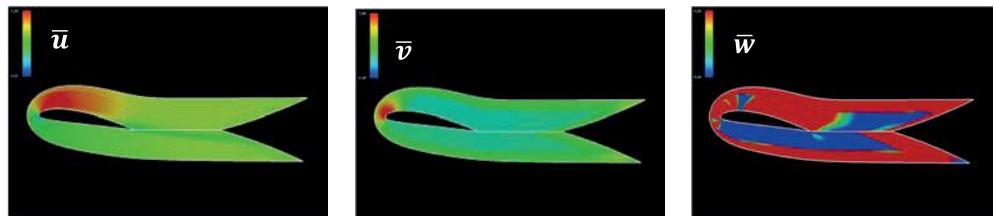
ビテーションが発生する領域は飽和蒸気圧に保たれ、 C_p 分布は $x/C=0 \sim 0.2$ のように平たんとなる。予測値から求めた C_p 分布も平たんな部分が $x/C=0 \sim 0.2$ に存在するが、値はテストデータから計算した C_p より小さい。 $\sigma=2.0$ の条件では $x/C=0 \sim 0.2$ にシートキャビティが定在する。一方、 $\sigma=1.2$ の条件ではシートキャビティ長さが振動し、 $x/C=0 \sim 0.2$ にキャビティが定在しないので、その流れ場を学習した NN が、シートキャビティが定在するときの圧力を予測できず、 C_p 分布の平たんな部分が小さくなつたと考えられる。

4. おわりに

キャビテーション流れの数値シミュレーションにおいて、数理モデルを代替する、データ駆動型キャビテーションモデルの枠組みを構築した。学習データセットには、簡易に取得・学習可能な二次元の CFD データを用いた。また、将来的に学習データセットとする計測データは、高々二次元であることが多いため、超解像ニューラルネットワークを用いて、三次元の流れ場に拡張を試みた。その結果、概ね定的には妥当な三次元流れ場を得たが二次元で計測できない速度の成分については予測できなかった。Physics-informed NN などの損失関数に物理的な特徴を含めるような工夫が必要と考えられる。



(a) テストデータ



(b) 予測値

図 4 : 拡張された速度場の時間平均・スパン方向平均分布[6]

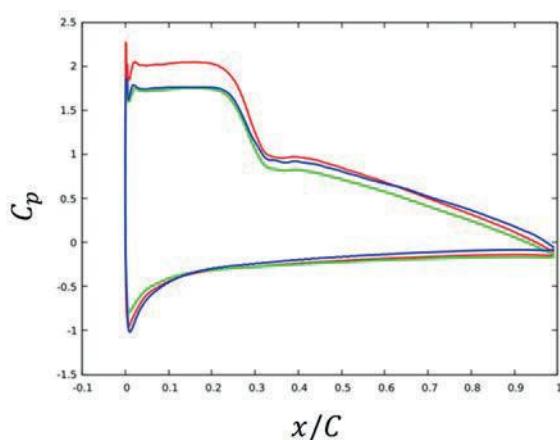


図 5 翼周りの圧力係数分布[6] (赤: テストデータ, 青・緑: 予測値 (青と緑はカーネルサイズが異なる))

参考文献

- (1) 岡村 俊吾, 岡林 希依, 混相流 (日本混相流学会誌論文特集: 混相流研究の進展) 掲載予定, (2023).
- (2) 岡林 希依, ながれ (注目研究 in CFD36) **42**(2), 87-90, (2023).
- (3) O. Ronneberger et al., Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), **9351**, 234-241, (2015).

- (4) 野田 隼司, 大阪大学修士論文, (2023).
- (5) C. Dong et al., IEEE Trans. Pattern Anal. Mach. Intell. **38**(2), 295-307, (2016).
- (6) 斎藤 有輝, 大阪大学卒業論文, (2023).