

畳み込みニューラルネットワークを用いた乱流パターンの分類：

円柱後流とチャネル乱流への適用

Classifying turbulent flow patterns using convolutional neural network: application to a cylinder wake and a turbulent channel flow

- 鈴木雄平, 明大院, 神奈川県川崎市多摩区東三田 1-1-1, E-mail: ce182033@meiji.ac.jp
中吉嗣, 明大理工, 神奈川県川崎市多摩区東三田 1-1-1, E-mail: naka@meiji.ac.jp
Yuhei Suzuki, Meiji University, 1-1-1 Higashimita, Tama-ku, Kawasaki-shi, Kanagawa
Yoshitsugu Naka, Meiji University, 1-1-1 Higashimita, Tama-ku, Kawasaki-shi, Kanagawa

A convolutional neural network (CNN) is applied to classify different turbulent flow patterns. The two-dimensional cylinder wake and three-dimensional turbulent channel flow are chosen for the present test cases. A CNN is constructed by the velocity data obtained using numerical simulations. For the cylinder wake, the CNN classifies the flow patterns at three different positions with high accuracy, but it drops to approximately 60% for the classification of 17 locations. This is because the flow patterns at adjacent locations are very similar when the cylinder wake achieves the self-similar state. For the turbulent channel flow, the recognition accuracy depends on the number of training data. For the classification of 12 flow patterns, comprising of three components and four wall normal locations, the recognition accuracy finally achieves 95% with 4500 training data sets.

1. 結論

乱流の流れパターンは、場所や各成分で異なっている。例えば、壁乱流の場合、速度分布のパターンは壁面からの距離や速度成分によって大きく異なる。乱流の流れパターンは数値計算や流れの可視化により得られるが、それらを理解するためには流れの物理に関する知識が必要になる。

近年では、深層学習を流体力学の諸問題に適用する試みが多くある。Lee (2017) らは敵対的生成ネットワーク (GAN) を用いて円柱上の不安定な層流渦流れを予測した⁽¹⁾。GAN を用いて予測された流れは、数値計算の解とよく一致した。Ling (2016) らは深層学習を用いて、RANS モデルの予測性能を向上するために、レイノルズ応力非等方テンソルのモデルを学習し、予測性能が改善することを確認した⁽²⁾。Jin (2018) らは複数の畳み込みニューラルネットワークを組み合わせることで、円柱後流の速度分布を予測した⁽³⁾。

深層学習の一種である畳み込みニューラルネットワークは画像認識に広く用いられており、様々な応用分野への適用性が検証されつつある。そのような画像認識の技術は、乱流のパターン分類を自動化し、乱流の特徴を理解する手助けになると考えられる。そこで、本研究では、深層学習を用いた画像認識の手法を、2次元の円柱後流と3次元のチャネル乱流に適用して異なる流れパターンの識別を試み、その適用性を明らかにすることを目的とする。

2. 円柱後流の流れパターン分類

2. 1. 数値計算

識別に用いる円柱の速度場は、OpenFOAM を用いた円柱周りの2次元数値シミュレーションにより得た。計算領域は、流れ方向、横方向にそれぞれ73*d*と25*d*の長方形スラブとした。ここで、*d*は円柱の直径である。時間ステップは無次元時間で0.025とし、クーラン数は1.3未満であった。シミュレーションは無次元時間 $t = 600$ まで行われた。円柱の直径と主流速度に基づくレイノルズ数は100とした。ブロック分割した計算領域を Fig. 1 に示す。円柱周りの格子点数は240、格子点の総数は66000とした。円柱近傍にはより多くの格子点を配置した。カルマン渦放出周波数から計算されるストローハル数は0.167で、文献値⁽⁴⁾とよく一致した。

2. 2. データセット

円柱後流での異なる3箇所の流れパターンを Fig. 2 に示す。これらは深層学習で分類する対象である。3箇所の領域は1辺2*d*の正方形で、領域(a), (b), (c)の中心は、それぞれ(-2*d*, 0), (2*d*, 0), (28*d*, 0)である。1つの領域での速度データは、各方向に26×26の676点をサンプリングした。 $t = 500$ から $t = 599$ の100のスナップショットについて、それぞれ3箇所、合計300個のデータを用いた。ここからランダムに抽出した30個を検証データとし、残りを訓練データとした。また、同様に $t = 300$ から $t = 399$ から300個のデータ抽出し、テストデータとして用いた。

さらに、分類難易度の高いケースとして、Fig. 3 に示すように分類対象が17箇所の場合での検証を行った。領域の大きさ及び各領域内のサンプリング点は、円柱後流の3箇所の分類の場合と同じとした。最も上流に近い領域の中心は(-3.5*d*, 0)、最も下流に近い領域の中心は(29.5*d*, 0)とした。

2. 3. ニューラルネットワークの構成

3箇所の分類に用いるニューラルネットワークの構成を Fig. 4 に示す。入力次元数は速度のデータ点と速度成分に対応する1352である。出力次元数は分類する流れの場所である、上流側、円柱の右側、遠く離れた下流に対応し、3となる。学習回数を100回、バッチサイズは100とした。活性化関数として、出力層にはソフトマックス関数を、他の層にはtanh関数を用いた。また、ニューラルネットワークの各層の結合を部分的に切断するドロップアウトを行い、その割合は20%とした。損失関数には以下のように定義される交差エントロピー*E*を用いた。

$$E = - \sum_{k=1}^K d_k \log y_k$$

*K*は分類対象の数、*d*は正解ラベル、*y*は出力ラベルである⁽⁵⁾。最適化手法にはAdam⁽⁶⁾を採用し、ニューラルネットワークの重み w^t は以下のように更新される。

$$m_{t+1} = \beta_1 m_t + (1 - \beta_1) g_t,$$

$$v_{t+1} = \beta_2 v_t + (1 - \beta_2) g_t^2,$$

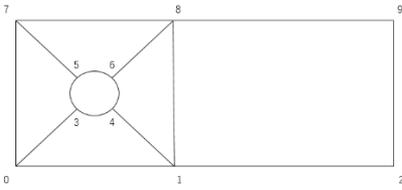


Fig. 1 Block division of the flow around a circular cylinder.

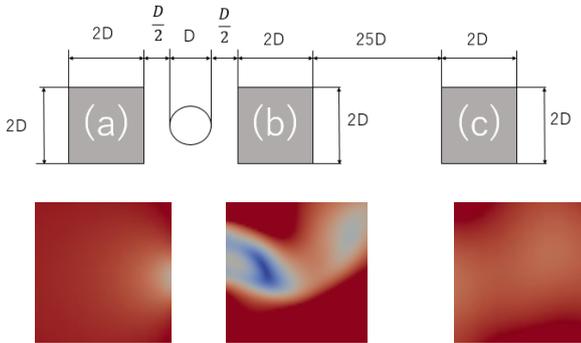


Fig. 2 Three positions in the flow around a circular cylinder.

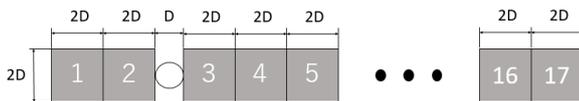


Fig. 3 Target of classification: 17 locations.

$$\hat{m} = \frac{m_{t+1}}{1 - \beta_1^t},$$

$$\hat{v} = \frac{v_{t+1}}{1 - \beta_2^t},$$

$$w^{t+1} = w^t - \alpha \frac{\hat{m}}{\sqrt{\hat{v} + \epsilon}},$$

ここで、 α は学習係数、 g_t は重みの勾配、 m_t と v_t はそれぞれ1次及び2次モーメントベクトルである。 β_1 と β_2 は指数関数的減衰率である。これらのニューラルネットワークの構成は、一般的に画像分類に用いられるものを採用した。学習の過程では、訓練データを入力した際に望みの出力が得られるよう、損失関数を最小化するようにニューラルネットワークの重みが調整される。適切に調整されたニューラルネットワークでは、訓練データ以外の同種のデータに対しても訓練データと同様の出力が得られる。一方で、訓練データ以外のデータで、損失関数が大きくなる場合には、過学習が起こっていると考えられ、訓練データを増やす等の対策が必要となる。

隣接する17箇所の分類では、Fig. 4に示すニューラルネットワーク及びFig. 5に示す畳み込みニューラルネットワーク(CNN)を用いて実験を行った。Fig. 5にはネットワーク内でのデータ形状及びデータに対する畳み込みの処理方法が記述されている。CNNの入力次元は、 $26 \times 26 \times 2$ であり、出力次元は分類箇所に対応する17である。活性化関数として、出力層の出力値にはソフトマックス関数を、他の層の出力値にはReLU関数を用いた。このCNNにもドロップアウトを採用し、その割合は、最初の畳み込み層で20%、その他の畳み込み層と全結合層で50%とした。損失関数、最適化手法はFig. 4と同様である。学習データは3箇所の分類と同じものを用いた。学習回数は1000回、バッチサイズは100とした。

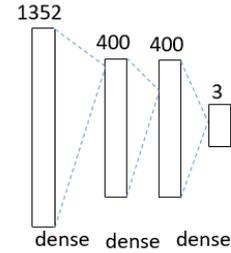


Fig. 4 Configuration of a neural network for classifying flow patterns of a cylinder flow.

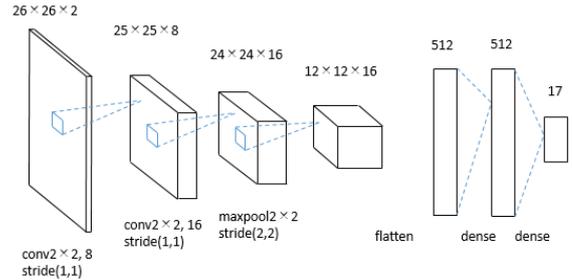


Fig. 5 Configuration of a convolutional neural network for classifying flow patterns of a cylinder flow.

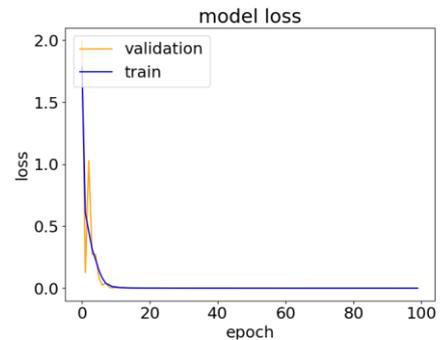


Fig. 6 Transition of loss function for classifying three flow patterns of a cylinder flow.

2. 4. 流れパターンの分類結果

3箇所の分類の際の損失関数の推移をFig. 6に示す。横軸は学習回数を、縦軸は損失関数の値を示す。青線は訓練データに、オレンジ線は検証データに対する損失関数の値である。両者の値は共に0に向かって収束し、テストデータの認識率は100%であった。17箇所の分類の損失関数の推移をFig. 7に示す。上図がニューラルネットワークによる分類結果、下図がCNNによる分類結果である。3箇所の分類と同様に、全結合での訓練データと検証データに対する損失関数の値は0に近づいたが、テストデータの認識率は61%と、3箇所の分類に比べて低下している。また、3箇所の分類では損失関数の値が学習開始直後に収束したのに対し、17箇所の分類では収束までに約200回の学習を要した。これは、問題が複雑になることで必要な学習回数が多くなったためと考えられる。17箇所の分類における場所ごとのテストデータの認識率をFig. 8に示す。場所1が上流で、場所17が下流である。下流のデータほど認識率が低くなっている。これは円柱後流が下流方向に発達すると隣り合う流れパターンが類似するようになるためだと考えられる。

CNNを用いて認識を行った場合、認識率は17箇所の分類で39%となった。またFig. 7に示すように、CNNの学習の際には訓練デ

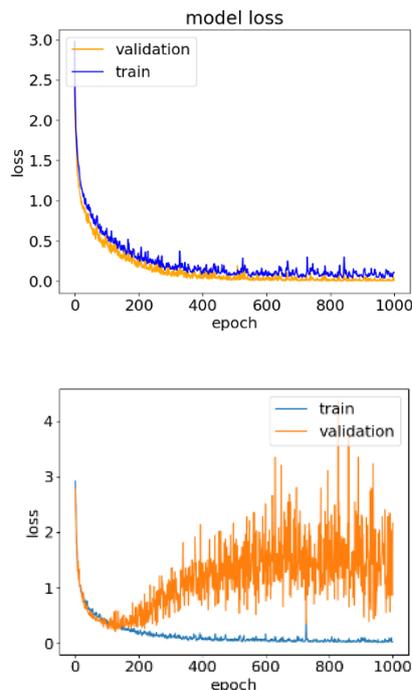


Fig. 7 Transition of loss function for classifying 17 flow patterns of a cylinder flow.

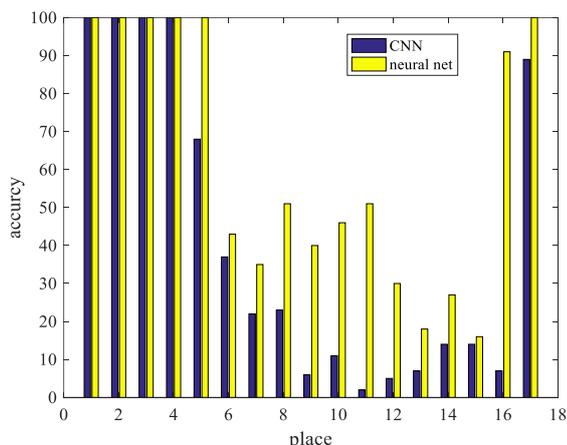


Fig. 8 Accuracy of CNN and neural network at different positions in the cylinder wake flow.

ータと検証データの損失関数の値に差が生じ、過学習が起きた。画像分類では Fig. 5 に示すようなニューラルネットワークの前段に畳み込みフィルタを置き、CNN とする構成が一般的に用いられ、全結合の場合よりも認識精度が高いことが知られている。これは、ピクセル単位よりも、ある領域で画像データの畳み込みを行ったデータの方が、画像の特徴をより反映したノードとなるためだと考えられる。今回のケースで全結合よりも畳み込みニューラルネットワークの認識率が低かったのは、この領域の抽出の際に、分類するために必要な流れの特徴量が失われたためだと考えられる。

3. チャネル乱流の流れパターン分類

3. 1. 数値計算

チャネル乱流の速度場は、OpenFoam を用いた数値シミュレーションにより得た。摩擦レイノルズ数は 180 とした。格子点数は x, y, z 方向である流れ方向、壁の垂直方向、スパン方向に対して

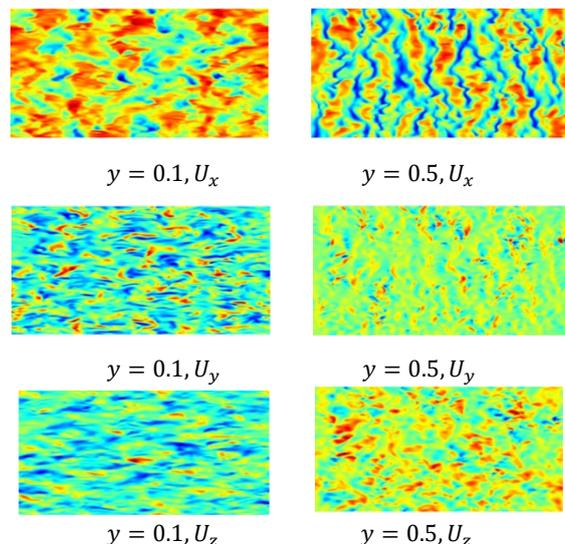


Fig. 9 Snapshot of x-velocity component of a turbulent channel flow. Color scale is arbitrary.

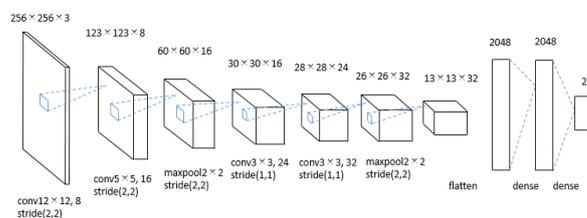


Fig. 10 Configuration of a convolutional neural network for classifying flow patterns at two locations of the channel flow.

$256 \times 192 \times 256$ とし、計算領域は、 $L_x \times L_y \times L_z = 4\pi \times 2 \times 2\pi$ とした。時間刻み幅はクーラン数が 1 を超えないように設定した。

3. 2. データセット

Fig. 9 に $y = 0.1, 0.5$ の 2 箇所の $x-z$ 平面における流れパターンを示す。速度データは x, y, z 方向にそれぞれ $256 \times 1 \times 256$ の次元を持つ。時間 $t = 50$ から $t = 78$ までの 29 個のスナップショットについて 2 箇所のデータを抽出した。さらに、中央面の対称性を用いることで、計 116 個のデータを得た。このうち、105 個を訓練データに、残りの 11 個を検証データに用いた。 $t = 79$ から $t = 106$ までについて、112 個のデータをテストデータに用いた。

さらに、分類の位置を増やしたケースについても検証を行った。チャネル乱流の $y = 0.04, 0.1, 0.5, 0.9$ の 4 箇所において、速度 3 成分、計 12 種類の流れを分類した。データの次元数は、チャネル乱流の 2 箇所の分類と同様である。 $t = 50$ から $t = 99$ までのデータから計 1200 個のデータを抽出した。このうち、1080 個を訓練データに、残りの 120 個を検証データに用いた。 $t = 100$ から $t = 109$ までについて、240 個のデータをテストデータに用いた。

3. 3. 畳み込みニューラルネットワークの構成

チャネル乱流の分類に用いる全ての CNN の活性化関数、損失関数、最適化手法、ドロップアウトの採用箇所とその割合は、前節で用いた CNN の条件と同一とした。Fig. 10 に 2 箇所の流れパターンを分類するための畳み込みニューラルネットワークの構成を示す。入力次元は $256 \times 256 \times 3$ で、2 箇所の分類であるため、出力次元は 2 とした。学習回数は 60 回、バッチサイズは 60 とした。

Fig. 11 に 12 種類の流れを分類するためのニューラルネットワークを示す。出力次元は 12、学習回数は 1000 回、バッチサイズは

