

畳み込みニューラルネットワークを用いた二次元流れ場の認識 Recognition of two-dimensional flow field using convolutional neural network

- 河崎太郎, 東大院, 千葉県柏市柏の葉 5-1-5, E-mail:t.kawasaki@daedalus.k.u-tokyo.ac.jp
- 鈴木隆洗, 東大院, 千葉県柏市柏の葉 5-1-5, E-mail:t.suzuki@daedalus.k.u-tokyo.ac.jp
- 山田健翔, 東大院, 東京都文京区本郷 7-3-1, E-mail:k.yamada@daedalus.k.u-tokyo.ac.jp
- 大道勇哉, JAXA, 東京都調布市深大寺東町 7-44-1, E-mail:ohmichi.yuya@jaxa.jp
- 金森正史, JAXA, 東京都調布市深大寺東町 7-44-1, E-mail:kanamori.masashi@jaxa.jp
- 鈴木宏二郎, 東大院, 千葉県柏市柏の葉 5-1-5, E-mail:kjsuzuki@k.u-tokyo.ac.jp

Taro Kawasaki, The University of Tokyo, 5-1-5 Kashiwanoha, Kashiwa, Chiba
 Takahiro Suzuki, The University of Tokyo, 5-1-5 Kashiwanoha, Kashiwa, Chiba
 Kento Yamada, The University of Tokyo, 7-3-1 Hongo, Bunkyo-ku, Tokyo
 Yuya Ohmichi, JAXA, 7-44-1 Jindaijihigashi, Chofu, Tokyo
 Masashi Kanamori, JAXA, 7-44-1 Jindaijihigashi, Chofu, Tokyo
 Kojiro Suzuki, The University of Tokyo, 5-1-5 Kashiwanoha, Kashiwa, Chiba

Convolutional neural network (CNN) has attracted attention by achieving outstanding performance in the field of image recognition. In the general object recognition method, an algorithm is used for extracting empirical features, so it was necessary to design a feature extractor according to tasks. On the other hand, the CNN can incorporate the feature extractor as one of the structures of the neural network, enabling object recognition independent of tasks. Therefore, in this study, the discrimination of the characteristic physical phenomena (separation, shock wave, vortex breakdown etc.) of the flow field solved by CFD is performed by CNN without designing the specific feature extractor. The present method is expected to be useful for the adaptive mesh refinement. In this study, the vortex breakdown phenomenon in the cylindrical container was selected as a benchmark to assess the performance of the CNN-based discrimination method.

1. 序論

近年の多層的な Neural Network (NN)を用いた深層学習 (Deep Learning) の発達により、高精度な一般物体認識や自然言語処理が可能となり、広く一般に大きなインパクトを与えている。中でも、Convolution Neural Network (CNN) ^[1]は、画像認識の分野で驚異的な性能を達成し注目を集めている。従来の機械学習を用いた一般物体認識手法では、検出対象に合わせて経験的な特徴量を抽出するアルゴリズムを用いるため、タスクに応じて特徴量抽出器の設計を行う必要があった。それに対して、CNN は特徴抽出器を NN の構造の一つとして組み込むことが可能となり、タスクによらない物体認識を可能とした。

一般物体認識は制約のない実世界画像を言葉によってのみ説明するタスクであり、古くから人工知能の究極的な目標の一つとされてきた。Fig.2 は一般物体認識のタスクの難易度を示す。

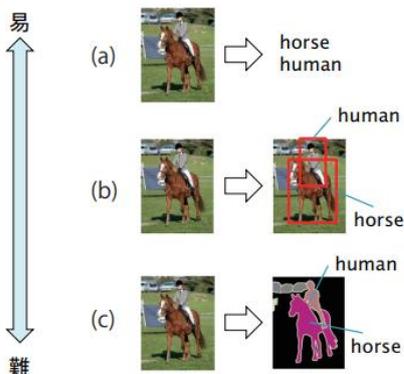


Fig. 2 一般物体認識の主要なタスク^[1].
 (a)物体カテゴリ識別. (b)物体検出. (c)物体領域抽出

2000年代では、SIFT や HOG 等の経験的な特徴量を抽出し、機械学習手法を組み合わせることで認識を行うシステムが優勢であったが、(1) 教師付き画像データ (画像+クラス名) が不十分であり、(2) 計算機パワーが十分ではなかった。2010年代では (1) ImageNet という大規模な教師付き画像データが公開されたこと、(2) GPU 技術の進歩により計算能力の著しい発達があったこと、(3) CNN が特徴抽出器として役割を果たし、タスクに対して適した構造であったことから、トロント大学の Hinton らのチームが一般物体認識におけるコンペティションで二位のチームに大差をつけて圧勝した。^[2]

一方、剥離や衝撃波、渦崩壊といった現象の検知は流体工学において非常に重要であり、解適合格子の生成等に有効であるが、従来手法では個々の現象に対する特徴量抽出器を設計する必要があった。^[2] そこで本研究では CFD で解いた流れ場の特徴的な物理現象 (剥離、衝撃波、渦崩壊等) の判別を CNN によって行い、タスクによらない検知手法の確立を目的とする。また、本研究の応用先として効率的な解適合格子の生成などが考えられる。本発表では研究の第一段階として、円筒容器内の渦崩壊現象の判別を行った。Fig.1 は本研究における概要を示す。本研究では従来手法と違い、深層学習を用いることで、タスクに依らない物理現象の検知手法の確立を目指す。

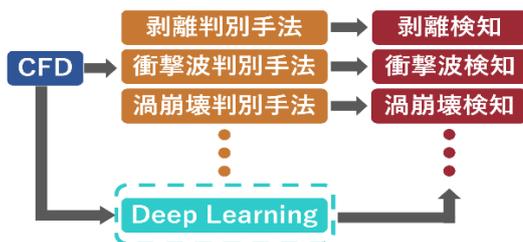


Fig. 1 本研究の概要

本研究目的をまとめると以下ようになる

- タスクに依らない流体现象の検知手法の確立
- 第一段階として二次元流れ場における渦崩壊現象を CNN によって判別

2. 流れ場の問題設定

本研究の判別対象には円筒容器内の渦崩壊現象を用いた。^[4] Fig.3 に示す円筒容器内渦崩壊現象では、バブル型と呼ばれる再循環領域が縦渦の回転軸付近に形成される。本研究で渦崩壊現象を対象とした理由として、Fig.4 に示すように速度ベクトル場のトポロジーが変わり流線の幾何学的構造に明らかな違いが見られ、CNN による判別が比較的容易であると考えられるためである。

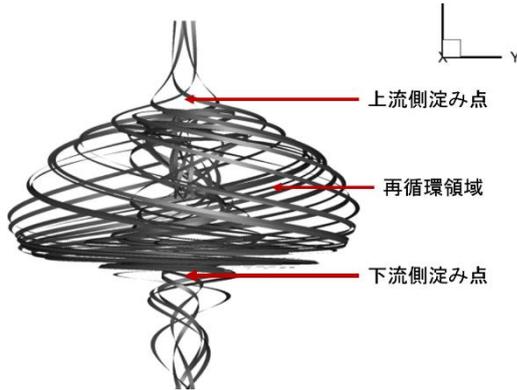


Fig.3 渦崩壊現象の構造

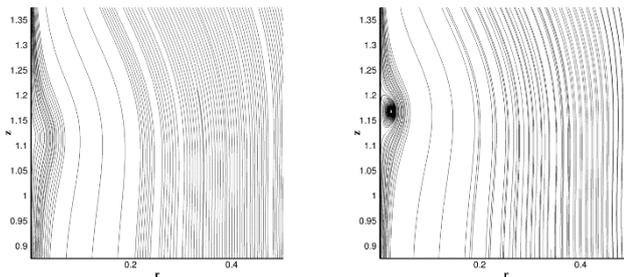


Fig.4 流線の幾何学的構造の違い

流れ場の計算には、山田ら^[5]によって開発された軸対称・低マッハ数流れソルバーを用いた。以下に計算条件の概略を示す。支配方程式は圧縮性ナビエ・ストークス方程式にマッハ数の二乗値を摂動とするオーダーアナリシスによって得られるもの^[6]を用いた。この方程式はマッハ数をゼロに近づけた極限が非圧縮ナビエ・ストークス方程式となることから、計算には非圧縮性流体の手法を用いることができる。今回は、対流項について補間型2次精度中心差分法^[7]で、その他の項について2次精度中心差分法で空間の離散化を行い、時間積分法には3次精度アダムス・バッシュフォース法と2次精度クランク・ニコルソン法のハイブリッドを用いた。

具体的なパラメータの設定は Table 1 に示される通りである。円筒容器内の渦崩壊現象は容器のアスペクト比と回転レイノルズ数によってまとめられる。圧縮性を考えていることからそれらに加えてマッハ数が追加されている。また、今回は上蓋の温度の境界条件を時間的に変化させることで、非定常な渦崩壊現象のデータを取得している。最大温度とは、設定上限の温度である。

Table 1 各種パラメータ

	Case 1	Case 2
アスペクト比 Δ	2	2
レイノルズ数 Re	1400	1100
マッハ数 M	0.01	0.01
基準温度 T_{ref}^*	300[K]	300[K]
最大温度 T_{MAX}^*	360[K]	360[K]

境界条件については図に示す通り、 $r = 0$ (容器中心軸) が軸対称条件、 $z = 0$ (下蓋) が等温回転壁、 $r = 1$ (側壁) が断熱固定壁、 $z = \Delta$ (上蓋) が温度可変の固定壁となっている。

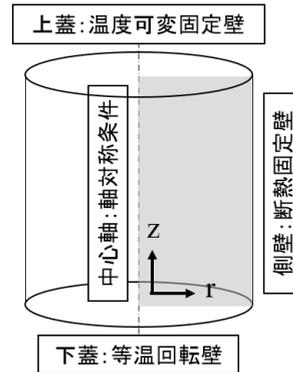


Fig.5 円筒容器の概略図

計算は温度勾配がついた静止流体の状態から $t=0$ において下蓋に回転が付加され、同時に上蓋に以下の式で表される温度が課される。

$$T(r, \Delta, t) = 1 + \left(\frac{T_{MAX}^*}{T_{ref}^*} - 1 \right) \cos\left(\frac{\pi t}{50}\right) \quad (1)$$

この温度の周期的な変化によって、バブル型渦崩壊を伴う流れ場にも周期的な変化が見られるようになる。計算格子は等間隔スタガード格子で、格子点数は r 方向に 128 点、 z 方向に 256 点となっている。両ケースについて $t=1000$ まで計算を行った際の密度の時間変化の様子が Fig.6 に示されている。

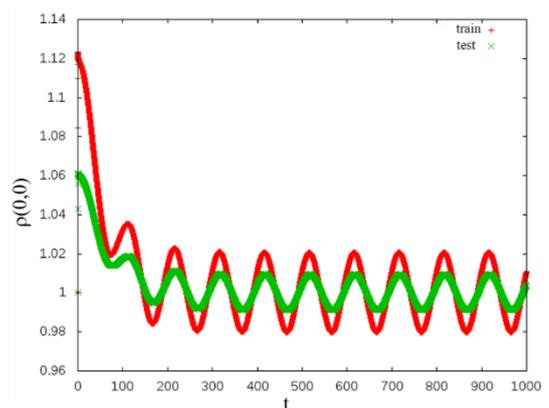


Fig.6 密度の時間変化

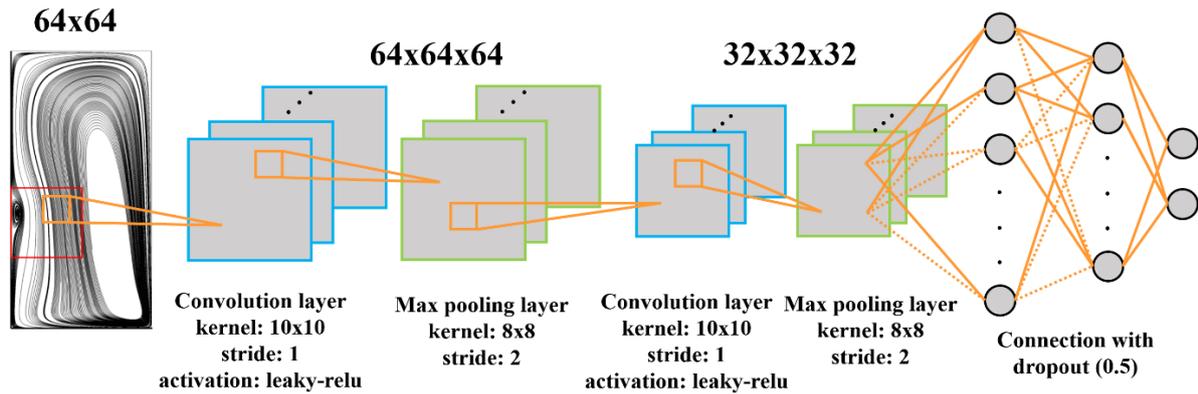


Fig. 7 CNN の構造

3. 流れ場認識の手法

本研究では Fig. 2 の(a)における画像のカテゴリ識別で用いられる CNN を参考にして、渦崩壊現象の判別を行った。本研究手法で使用した CNN の構造を Fig. 7 に示す。本研究手法は 1. 対象領域の決定, 2. 訓練データの作成, 3. CNN を用いた分類, の三つのステップから構成される。

3.1. 対象領域の決定

今回は、対象領域は計算領域全体ではなく、渦崩壊現象が発生している近傍のみに限定して行った。理由として、渦崩壊現象に対して影響の少ないと考えられる流れ場を訓練データとして含めることで、NN の誤差計算の収束に悪影響を与えられとされるためである。Fig. 8 の左上図に示すように計算領域全体 (128×256) に対して、Fig. 8 の右上図の赤枠で囲まれた計算領域 (64×64) を対象領域として、訓練データを作成した。Fig. 8 の左下図と右下図に示すように、検証データに対しても同様の処理を行った。両データ共にバブル型渦崩壊が赤枠の内部に完全に捉えられる範囲となっている。

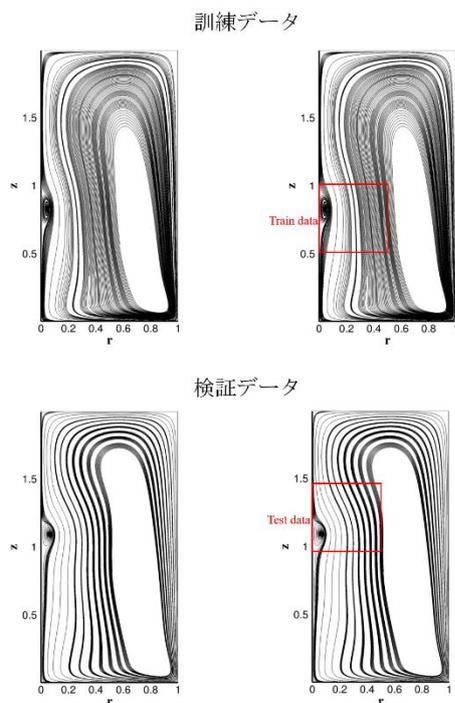


Fig. 8 対象領域の決定

3.2. 訓練データと検証データの作成

Table 1 において、Case 1 を訓練データ、Case 2 を検証データと設定した。本手法では 3.1. で得られた対象領域は正方形のグリッドで区切られ速度ベクトル U, V が格納されているため、画像の RGB の代わり速度ベクトルの値を用いた。また、渦崩壊が発生した場合、していない場合の判別は人間が CFD の可視化結果から行い、ラベルを生成した。訓練データ、検証データは非定常流れである本計算ケースを一定間隔で区切って作成され、Table 2 において各データ数を示す。

Table 2 本研究で作成したデータ数

	渦崩壊有り	渦崩壊無し
訓練データ	214	786
検証データ	703	297

3.3. CNN を用いた分類

CNN について説明を行う。⁸⁾ CNN の入力層は $N \times M$ のグリッドに格納された速度ベクトル U, V であるため、大きさは $N \times M \times 2$ となる。中間層は convolution 層と pooling 層の 2 層を基本モジュールとして、複数連続して接続されている。最終層は分類クラスと同数のユニットを設置し、判別結果を示す。

3.3.1. Convolution 層

Convolution 層の役割は、入力データから特徴的な構造を抽出することである。 $N \times M \times 2$ の大きさのデータの位置 (i, j, k) の流れ場の速度を $x_{i,j,k}$ 、フィルターの種類を R 種類、フィルターのサイズを $H \times H$ として、 r 種類目のフィルターの位置 (p, q, r) の流れ場の速度を h_{pqkr} とすると、畳み込みは

$$u_{ijr} = \sum_{k=0}^2 \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} x_{i+p,j+q,k} h_{pqkr} + b_r \quad (2)$$

として計算でき、 $b_r (r = 0, \dots, R)$ はバイアス項であり、フィルター毎に共通の値を用いた。 u_{ijr} に活性化関数を適用した値が convolution 層の出力 z_{ijr} となる。今回の場合、1 層目と 2 層目における convolution 層のフィルターサイズ H は 10、ストライドは 1 と設定した。

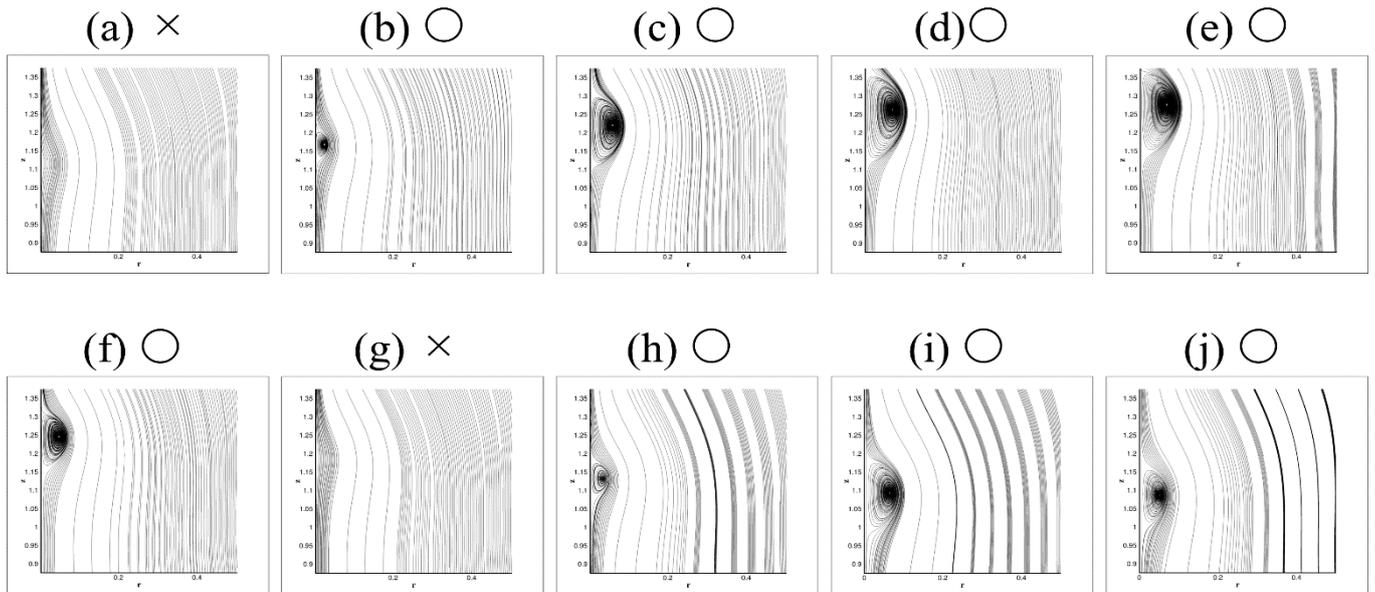


Fig.9 周期変化の中から $t=10$ おきに抜粋した流れ場
×は誤った判別のケース, ○は正しい判断のケースを示す.

3.3.2. Pooling 層

pooling 層では, convolution 層の出力層の小領域の中から代表値がサンプリングされる. pooling 層の役割は, convolution 層で抽出されたデータの特徴の若干の位置ずれの吸収や, データ量の削減を行う. convolution 層の出力における小領域の位置を座標 (i, j) , 座標 (i, j) の小領域を P_{ij} とすると, max-pooling は

$$\hat{z}_{ijr} = \max_{(p,q) \in P_{ij}} z_{pqr} \quad (3)$$

と計算される. 今回の場合, 1層目と2層目における pooling 層のフィルターサイズは8, スライドは2と設定した.

3.3.3. 全結合層

全結合層では, convolution 層と pooling 層によって抽出された特徴をもとに, 入力の二次元流れ場で渦崩壊現象が生じているかの判別を行う. クラスは, 入力を $x_i (i = 1, \dots, n)$ とすると, softmax 関数を用いて

$$\hat{j} = \operatorname{argmax}_j \frac{\exp(x_j)}{\sum_{k=1}^n \exp(x_k)} \quad (4)$$

と推定される. 本手法において, クラスは渦崩壊現象が生じているか, 生じていないかの2つである. CNN の学習は, 誤差逆伝播法によってフィルター係数 h_{pqkr} , バイアス係数 b_r , 全結合層の重みの更新が行われる.

4. 結果

Table 3 判別結果

	正解数	失敗数
訓練データ	999	1
検証データ	836	164

Table 3 は本研究手法を用いて渦崩壊現象を判別した結果を示す. また, 訓練データを用いて学習を始め, 学習が収束するまでに掛かった時間は約 6(h)であった. 訓練データにおいて判別結果の正答率が約 100%で収束したことから, 学習を終了させた. 訓練デー

タで学習させたモデルに対して検証データの判別を行った所, 正答率は 83.6%であった. ここで, 検証データにおいて判別を誤ったケースについて考える. Fig.9 は, 流れ場の周期的な変化の中から1周期を $t=10$ おきに抜粋した画像である. Fig.9 において, (a)から(j)の順で流れ場を掲載しており, (a)から(b)にかけて渦崩壊現象が生じ始め, (b)から(g)にかけて渦崩壊現象が消失し, (g)から(j)にかけて再度, 渦崩壊が生じている. また, (a)から(j)の横の×は誤った判別のケース, ○は正しい判断のケースを示す. この中で, Fig.8 の(a)の渦崩壊が生じる直前と(g)の渦崩壊が消失した直後のみ, 渦崩壊の判別を誤った. これは, 渦崩壊が生じる直前と直後や, 消失する直前と直後において流れ場が似ており, 上手く区別できず誤った判別を行ったと考えられる. しかし, 誤った判別を行った箇所が無作為に出現しているのではなく, 渦崩壊が生じる直前と直後の判別が微妙になる場合のみに見受けられた. このことは, 訓練データによって本研究の趣旨に沿った学習が行えたと考えられ, 本研究の有効性を示す.

5. 結論

本手法では, CFD で解いた流れ場の特徴的な物理現象(剥離, 衝撃波, 渦崩壊等)の判別を CNN によって行う第一段階として, 二次元流れ場における渦崩壊現象の判別を行い, 高い正答率を得ることができた. また, 本研究は渦崩壊現象の判別を行うために特有の手法を使うことなく高い正答率を得ることができた. さらに高い正答率を得るためには, 訓練データにおいて渦崩壊が有る場合, 無い場合のデータ数を同じすることや, 訓練データのデータ数自体を増やす data augmentation も有効であると考えられる. また, 本手法は二次元流れ場において Fig.2 における(a)データの識別の可能性を示したが, (b)物体検出を行うことを次の目標とする. つまり, 今回はユーザーが対象領域の決定した後に渦崩壊の判別を行ったが, 対象領域自体も明示したプログラムによってではなく, 自動で決定することが可能になる.

謝辞

本研究は JAXA 航空技術部門からの受託研究の一環として実施

された。

参考文献

- (1) Krizhevsky, Alex. Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." In *Advances in neural information processing systems*, pp. 1097-1105. 2012.
- (2) Wu, Z., Xu, Y., Wang, W. and Hu, R., "Review of shock wave detection method in CFD post-processing." *Chinese Journal of Aeronautics* 26.3 (2013), pp501-513.
- (3) 中山, "深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習", 信学技報, 115.146, 2015
- (4) Escudier, M. P., "Observations of the flow produced in a cylindrical container by a rotating endwall," *Exp. In Fluids*, 2 (1984), pp. 189-196.
- (5) Yamada, K. and Suzuki, K., "Compressibility Effect on Topology of Vortex Ring Formed by Vortex Breakdown in Closed Cylinder at Low-Mach-Numbers," AIAA Paper 2017-3679.
- (6) Majda, A., and Sethian, J., "The derivation and numerical solution of the equations for zero mach number combustion," *Combust. Sci. Tech.*, 42 (1985), pp.185-205.
- (7) 梶島, "乱流の数値シミュレーション 改訂版," 養賢堂, (2014).
- (8) 立花, 松原, 上原, "深層学習における教師なし特徴抽出手法の比較." 情報処理学会関西支部 支部大会 講演論文集 2015 (2015).