

令和 5 年 6 月 12 日現在

機関番号：14401

研究種目：挑戦的研究（萌芽）

研究期間：2020～2022

課題番号：20K20973

研究課題名（和文）機械学習による乱流エネルギー散逸率の予測と乱流モデル

研究課題名（英文）Inference of the energy dissipation rate and construction of turbulence model by machine learning

研究代表者

後藤 晋（Goto, Susumu）

大阪大学・大学院基礎工学研究科・教授

研究者番号：40321616

交付決定額（研究期間全体）：（直接経費） 4,800,000円

研究成果の概要（和文）：機械学習による乱流モデルの構築の可能性の検証を行った。(1) 乱流モデルにおける基本物理量であるエネルギー散逸率の時系列をグリッドスケールの情報から予測するニューラルネットワーク(NN)が構築可能なことを示した。(2) 低レイノルズ数の乱流の時系列データを用いて訓練したNNをより高いレイノルズ数の乱流の時系列データに転移可能であることを示した。これは乱流モデルの構築において本質的であり、物理的には乱流の小スケールの統計の普遍性に依る。(3) 乱流の疎結合シェルモデルを用いた実証を行い、切断波数を普遍領域におき、NNのパラメタを適切に設定すれば、安定かつ高精度なモデル化が可能であることを示した。

研究成果の学術的意義や社会的意義

これまで流体の運動方程式に基づいた乱流モデルの構築が目指されてきたが、方程式の非線形性がその成功を阻んできた。一方で、機械学習が多くの分野で成功を収めたことで、乱流モデルへの応用の期待も高まっている。本研究では、機械学習を乱流モデルへと闇雲に適用するのではなく、我々がもつ乱流の動力学や統計に関する知見を活かした適用を考えた。実際、乱流のエネルギーカスケードに起因する因果関係や、その普遍性に基づく転移学習の可能性など、乱流の知見が機械学習の適用においても本質的であることを明らかにした。さらに、乱流のトイモデルに対するモデル化も実証できた。これらは、今後の関連研究の基盤を与える成果である。

研究成果の概要（英文）：We have conducted a feasibility study for turbulence modeling by using machine learning. (1) First, we have shown that we can construct an artificial neural network (NN) inferring the time series of energy dissipation rate, which is one of the most important quantities in turbulence modeling, from grid-scale information. (2) Next, we have shown that the NN trained with the data of turbulence at a relatively low Reynolds number can be transferred to predict the time series of turbulent energy dissipation rate at higher Reynolds numbers. Such possibility of transfer learning is essential when we apply machine learning to modeling. Note that the small-scale universality of turbulence enables us to use this technique. (3) Then, we have demonstrated the possibility of stable and accurate modeling for the sparse-coupling shell model of turbulence. More concretely, we can construct the model by appropriately setting hyper parameters according to the cut-off wavenumber.

研究分野：流体工学

キーワード：乱流 機械学習 乱流モデル エネルギー散逸率 数値シミュレーション リザバーコンピューティング シェルモデル

科研費による研究は、研究者の自覚と責任において実施するものです。そのため、研究の実施や研究成果の公表等については、国の要請等に基づくものではなく、その研究成果に関する見解や責任は、研究者個人に帰属します。

## 1. 研究開始当初の背景

乱流は我々の身のまわりにありふれた現象であり、その予測や制御はさまざまなシステムで必須である。近年の計算機環境の劇的な改善により、多くの乱流現象が数値的に予測可能となりつつある。このとき、しばしば『乱流モデル』が用いられる。つまり、乱流の小スケールの普遍性に基づいて乱流の小スケールの運動をモデル化することで、計算機資源に限られている場合でも乱流の大スケールの運動に関する予測が可能となる。

ところで、従来の乱流モデルでは流体の基礎方程式に基づいた方程式系が用いられてきた。しかし、基礎方程式の非線形性のために、これらの方程式は何らかの粗い近似のもとに導かれたものであり、その数理的な根拠は乏しい。一方で、近年急速に発達している機械学習を適切に利用することで、基礎方程式の非線形性に起因するこの困難を克服し、これまでにない新しい乱流モデルを構築する気運が高まった。

## 2. 研究の目的

(1) 乱流モデルを構築するための第一段階は、小スケールの物理量をグリッドスケール(つまり、乱流モデルを用いた数値シミュレーションで解像している大スケール)の物理量から予測することである。ここでは、小スケールの物理量の代表として、エネルギー散逸率 $\epsilon$ を考える。これは、 $\epsilon$ が乱流の動力学を考える上で最も基本的な量であるためである。たとえば、『乱流の小スケールの統計は $\epsilon$ と流体の動粘性係数 $\nu$ で決まる』というコルモゴロフの相似仮説において、 $\epsilon$ が中心的な量であることは言うまでもなく、また、代表的な乱流モデルのひとつである $K - \epsilon$ モデルでは、運動エネルギー $K$ とその散逸率 $\epsilon$ から乱流の渦粘性係数を評価する。 $K - \epsilon$ モデルに限らず、一般に乱流モデルでは、何らかの形でエネルギー散逸率 $\epsilon$ の動力学をモデル化する必要がある。多くの場合、テーラーの散逸則と呼ばれるエネルギー散逸率の時間平均値の評価式を流用するが、平均値に対する式を動力学に用いてよいという根拠はない。

ところで、乱流はいわゆるエネルギーカスケード現象により維持されると考えられる。この現象は、外力や平均流により生成された乱流中の大スケールの渦から、エネルギーがより小さなスケールの渦へと順繰りに伝達され、やがて最小スケールの渦の運動エネルギーが散逸されて熱に変換されるというものである。エネルギーカスケード現象の解明自身が乱流の大きな問題のひとつであるが、いずれにしても、エネルギーが大スケールから小スケールへと伝わるということは、乱流の大スケールの情報と小スケールの情報の間には明確な因果関係があることを示唆する。したがって、これまで困難とされてきた小スケールの物理量をグリッドスケールの情報を用いて記述することは、原理的には難しくない可能性がある。本研究ではこの点に着目し、大スケールの情報を入力にして小スケールの情報を出力するニューラルネットワーク(NN)が構築可能であることを示す。

(2) 機械学習は内挿であると言われる。つまり、一般には、教師データに含まれない情報が入力された場合に、その予測が破綻する可能性が高い。一方で、乱流のエネルギーカスケード現象には普遍性があることが知られる。つまり、乱流のエネルギーカスケードの仕組みは、乱流の駆動機構やレイノルズ数に依らずに普遍的である。したがって、この普遍性に着目すれば、たとえば、上述の(1)のエネルギー散逸率の予測に関して、『転移学習』が可能である可能性がある。そこで本研究では、あるレイノルズ数の乱流の教師データを用いて訓練したNNをより高いレイノルズ数の乱流の物理量の予測へと転移可能であることを示す。

実は、転移学習は機械学習による乱流モデルを考える上で本質的である。なぜならば、高いレイノルズ数のデータが容易に入手可能であるならば、そもそもモデルは不要だからである。つまり、低レイノルズ数の乱流に対する豊富な教師データを用いてNNの訓練を行い、これをより高いレイノルズ数の乱流の物理量の予測に転移することは、乱流モデルの構築のために必須である。

(3) 最後に、具体的な乱流モデルの構築の実現性を示す。本研究課題を進めるうちに、流体の基礎方程式(ナビエ・ストークス方程式)に従う乱流に対するモデル化の原理、限界、あるいは性能を評価するためには、より素朴な非線形力学系における詳細な検討が必須であることが分かってきた。つまり、機械学習で用いるNNには多くのハイパーパラメタがあるので、モデルの成否が乱流の物理に起因する本質的なものなのか、ハイパーパラメタの選択によるものなのかをはっきりと切り分けることが、極めて重要であることが分かってきた。そこで、本研究では乱流のトイモデルであるシェルモデルを採用し、これに対して徹底的な検討を行うことで、機械学習の乱流モデルへの適用可能性を示す。

## 3. 研究の方法

前項で述べた 3 つの研究の目的を達成するために、それぞれ、以下の 3 つの研究を計画し、これらを実行した。

(1) 周期境界条件下の乱流のエネルギー散逸率 $\epsilon$ の予測を考える。具体的には、まず、あるレイノルズ数における乱流の直接数値シミュレーションを実行し、乱流の運動エネルギーの空間平均値 $K(t)$ とエネルギー散逸率の空間平均値 $\epsilon(t)$ の十分に長い時系列を得る。一般に、前者は乱流中の最大スケールの渦により決まるので計測が容易であり、また、乱流モデルを用いた数値シミュレーションでも解像しているスケールの情報からこれを評価可能である。一方で、後者は乱流中の最小スケールの渦により決まるので、乱流モデルではこれを解像しているスケールの情報から予測する必要がある。そこで機械学習による乱流モデルの構築の可能性を検証するために、得られた時系列を教師データとして NN を訓練し、 $K(t)$ から $\epsilon(t)$ の予測が可能であることを示す。

研究の目的でも述べたように、エネルギーカスケード現象により、後者は前者に追従して時間発展するので、前者から後者を予測する NN を構築することは難しくはないはずである。ここでは、このことを数値的に示すために、NN としてリザーバーコンピューティング (RC) と呼ばれるリカレントニューラルネットワーク (RNN) を用いる。RNN は時系列予測に長けており、また、RC はその学習が容易であるという特長がある。

(2) (1) で構築したエネルギー散逸率を予測する RC が転移可能であることを示す。具体的には、低レイノルズ数 (典型的には、空間解像度  $32^3$  の極めて小規模な直接数値シミュレーションで実現できるレイノルズ数、テラー長レイノルズ数で 30 程度) の長時間時系列を教師データとし、これを用いて RC を訓練する。(1) で示したように、この RC はこのレイノルズ数の乱流のエネルギー散逸率をよく予測する。

まず、この RC をそのままより高いレイノルズ数の乱流のエネルギー散逸率の予測に用いることができることを示す。次に、『転移率』という概念を導入し、高いレイノルズ数の乱流の数値シミュレーションに得られた情報を部分的に教師データとして用いることで、単に低いレイノルズ数で訓練した RC を転移するよりも、その予測精度が向上することを示す。

(3) 機械学習による乱流モデルの構築の可能性を示すために、疎結合シェルモデル (Sparse-Coupling Shell Model, 以下では SCSM と略す) と呼ばれる乱流のトイモデルに対するモデル化を検証する。シェルモデルでは $\ell$  ( $= 1, 2, \dots, L$ ) を自然数として、 $2^\ell$ と $2^{\ell+1}$ の間の大きさの波数をもつモードを一括りにして『シェル』と呼ぶ。つまり、各シェルはある波数帯 (つまり、あるスケール帯) を代表する。さらに、乱流のエネルギーカスケードがスケール局所に起こることを想定し、シェルモデルでは隣接するシェルどうしのみが相互作用をする。この特性により SCSM に対する乱流モデルは、ナビエ・ストークス方程式のモデル化に比べて容易である。この利点を利用し、SCSM の機械学習によるモデル化を行い、その可能性を検証する。

SCSM に対するモデル化の具体的な手続きは以下の通りである。シェルの番号を $\ell$  ( $= 1, 2, \dots, L$ ) としたとき、 $\ell = 1$ が最低波数 (最大スケール) のシェル、 $\ell = L$ が最大波数 (最小スケール) のシェルに対応する。乱流モデルの目的は、ある切断波数 (SCSM では切断シェル番号  $\ell_c$ ) よりも低波数 (大きなスケール) のみで閉じたモデルを作ることである。SCSM では、 $\ell$  番目のシェルのモードは、 $\ell \pm 1$  のシェルのモードとのみ相互作用するので、 $\ell = 1, 2, \dots, \ell_c$  で閉じたモデルを構築するためには、これらの解像スケールの情報から  $\ell_c + 1$  のモードを予測すればよい。したがって、NN (ここでも、RC を用いる) を用いてこの予測を実現し、予測した  $\ell_c + 1$  番目のシェルの情報と元の支配方程式を組み合わせることで、 $\ell = 1, 2, \dots, \ell_c$  のモードだけで閉じたモデルが完成する。

#### 4. 研究成果

(1) 周期境界条件下の乱流の空間平均運動エネルギー $K(t)$ とその散逸率 $\epsilon(t)$ の時系列を図 1 (a) および図 1 (b) に示す。これらの図で、時刻は乱流の積分時間 $T$ で規格化して示した。それぞれの時系列は時間的に大きく変動する

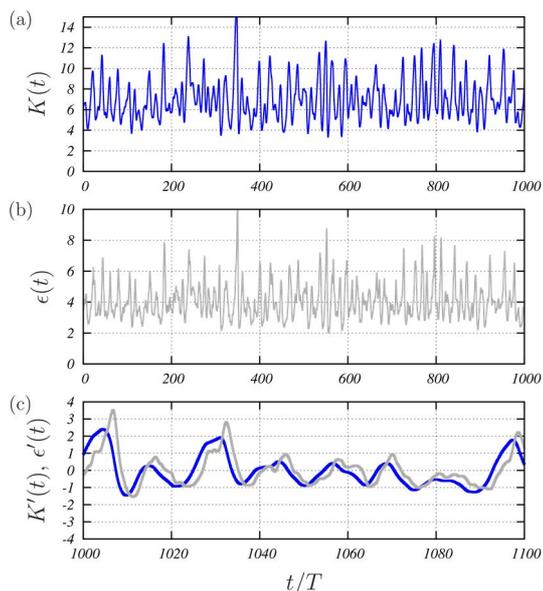


図 1 周期境界条件下の乱流の(a)運動エネルギー $K(t)$ と(b)エネルギー散逸率 $\epsilon(t)$ の空間平均の時系列。(c)はそれぞれの平均値と標準偏差で正規化した時系列。 $\epsilon(t)$ が $K(t)$ に追従して時間発展することが分かる。

が、そのふるまいは準周期的であり特徴的な周期（およそ $20T$ ）をもつことが分かる。また、 $K(t)$ と $\epsilon(t)$ の時系列を重ねて示す（図1(c)）と、 $\epsilon(t)$ の時系列は、 $K(t)$ の時系列におよそ積分時間の2から3倍ほどの時間だけ遅れて追従することが分かる。ここで、 $\epsilon(t)$ および $K(t)$ が、それぞれ小スケールおよび大スケールの流れ構造の活発度に対応することを思い出せば、この時間遅れがエネルギーカスケードによるものであることが分かる。

そこで、ある時刻 $t$ の運動エネルギー $K(t)$ を入力として、同時刻のエネルギー散逸率 $\epsilon(t)$ を出力とするRCを十分に長い教師データを用いて訓練し、教師データに含まれない時系帯におけるエネルギー散逸率の予測を行った結果を図2に示す。かなり良好な予測が行えていることが確かめられる。

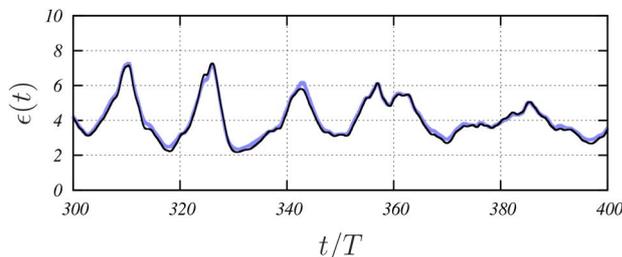


図2 周期境界条件下の乱流 ( $R_\lambda \approx 35$ ) のエネルギー散逸率 $\epsilon(t)$ の空間平均の時系列の NN による予測（黒線）。青線が真値を表す。極めてよい精度で予測ができていることが分かる。

(2) 上で訓練したRCを他のレイノルズ数へと転移した結果を図3に示す。つまり、低レイノルズ数 ( $R_\lambda \approx 35$ ) の豊富な教師データを用いて訓練したRCを、より高いレイノルズ数 ( $R_\lambda \approx 120, 280, 750$ ) の乱流の運動エネルギーの空間平均値を入力として、そのエネルギー散逸率の空間平均値の予測に用いた結果を示す。とくに、図3(c)は、ここで検討した最も大きなレイノルズ数 ( $R_\lambda \approx 750$ ) に対する結果であり、真値は解像度が $2048^3$ の直接数値シミュレーションで得られたものである。つまり、直接数値シミュレーションが容易ではないような高いレイノルズ数の乱流であっても、転移学習を用いることで、小スケールの物理量の予測が可能であることが分かった。このことは、機械学習を用いた乱流モデル構築の可能性を考える上で極めて重要な結果である。

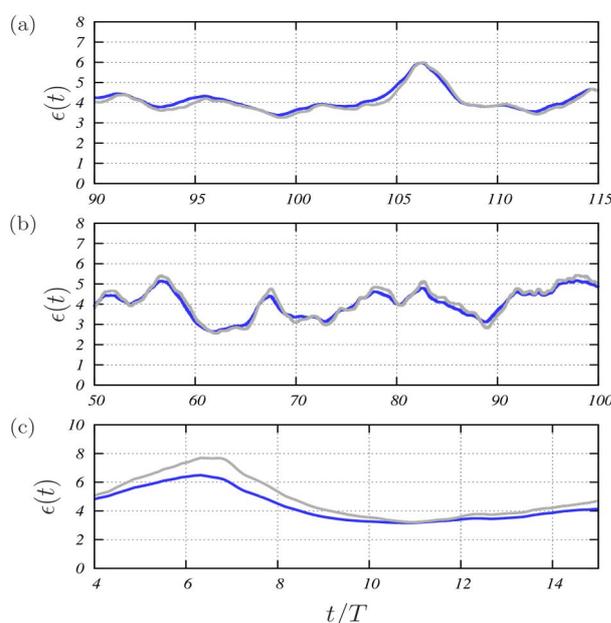


図3 周期境界条件下の乱流 ( $R_\lambda \approx 30$ ) の時系列データを教師データとして訓練したRCをより高いレイノルズ数 ((a)  $R_\lambda \approx 120$ 、(b) 280、(c) 750) の乱流のエネルギー散逸率 $\epsilon(t)$ の空間平均の予測（灰色の線）に転移した結果。青線が真値を表す。レイノルズ数が大きく異なっても転移学習が可能であることが分かる。

さらに、本研究では転移率という概念を導入する。つまり、目的系(上の例であれば、より高いレイノルズ数の系)において教師データが少量でも得られている場合に、これを用いることでNNの能力を高められる

かを検討する。具体的には、転移率 $\mu$ が0の場合は、転移を全く行わず目的系において通常の実験を行うことを意味する。一方で、転移率 $\mu \rightarrow \infty$ は目的系の教師データが全く得られない場合に相当し、素朴に転移学習を行うことを意味する。当然ながら、目的系における教師データが十分にある場合には $\mu = 0$ とすることで誤差は小さくなる。文献のFIG. 4は転移率 $\mu$ と予測誤差の関係を示す。図3の結果からも予想される通り、 $\mu \gg 1$ としても良好な予測が可能であることと、最適な $\mu$ の値は比較的大きいことが分かる。これは乱流のエネルギーカスケード現象がレイノルズ数に弱くしか依存しないことによると理解できる。

なお、文献では、ローレンツ系を用いた転移学習に対する結果も示した。さらに、予備的ではあるが、乱流のエネルギー散逸率の空間分布の予測に対しても(1)(2)に関する結果を得ており、近く投稿論文にまとめる計画である。

(3) 以上の結果により、乱流のエネルギーカスケード現象に着目すれば、乱流モデルが構築可能であることが強く示唆された。次の段階は、実際のモデルを構築し、その性能を評価することになる。我々はこれを目指してナビエ・ストークス方程式に支配される乱流のモデル構築を試みたが、例えばモデル化が失敗した場合に、それが乱流の動力学による問題によるのか、あるいは、

NNのハイパーパラメタの設定の問題なのかを切り分けることが難しいと感じた。そこで、研究の方法(3)で述べた通り、乱流のトイモデルであるSCSMに対するモデルの構築を行い、その性能を調べた。

乱流モデルは、ある切断波数以下のモードのみで閉じたモデルである。したがって、SCSMに対するモデルは、ある切断シェル番号 $\ell_c$ 以下のシェル番号に属するモードのみでモデルを構築する。まず、切断シェル番号 $\ell_c$ に対応する切断波数を慣性領域に置くか、粘性領域に置くかでモデル化の難易度が大きく異なることが分かった。後者の場合の方がモデル化は容易である。とくに、切断シェル番号に対応する切断波数がコルモゴロフ波数の0.2倍程度よりも大きい場合には、とくにNNのハイパーパラメタの調整を行わなくても、シェル番号 $\ell_c + 1$ のモードの予測さえできていれば、乱流モデルの構築が可能となる。このことは、このような高波数域に切断波数を置くと、モデル化される高波数のモードが解像されている低波数のモードに隷属的になる(文献 および を参照)ためであると理解できる。

しかし、本来、切断波数は乱流の普遍領域内であれば任意に選べるはずである。本研究によれば、切断波数を慣性領域に置いた場合に精度がよくかつ安定なモデルを構築するためには、シェル番号 $\ell_c + 1$ のモードの予測精度を高めることに加えて、その予測の際の正則化パラメタ $\beta$ の選択が重要であることが分かった。図4には、切断シェル番号を $\ell_c = 12$ (粘性領域)とした場合と $\ell_c = 6$ (慣性領域)とした場合に、構築したモデルにより得られた最低波数のモード $X^{(1)}$ の確率密度関数 $P(X^{(1)})$ および、 $X^{(1)}$ の二時刻自己相関関数 $C(\tau)$ を示した。いずれの切断シェル番号の場合であっても、正則化パラメタを適切に設定(ここでは、 $\beta = 10^{-5}$ とした)することで極めてよい精度でモデル化が可能であることが確かめられる。このことは、確かに機械学習により乱流モデルの構築が可能であることを強く示唆する。現在、系統的なパラメタサーベイを行い、適切な正則化パラメタ $\beta$ の選択方法を整理しており、近日中に論文を投稿する。もちろん、ここで得られた知見を基にして、今後はナビエ・ストークス方程式に支配される乱流のモデル化の可能性検証を進める計画である。

#### <引用文献>

M. Inubushi and S. Goto, Transfer learning for nonlinear dynamics and its application to fluid turbulence, *Phys. Rev. E* **102**, 043301 (2020).

K. Yoshida, J. Yamaguchi, and Y. Kaneda, Regeneration of small eddies by data assimilation in turbulence, *Phys. Rev. Lett.* **94**, 014501 (2005).

T. Yoneda, S. Goto, and T. Tsuruhashi, Mathematical reformulation of the Kolmogorov–Richardson energy cascade in terms of vortex stretching, *Nonlinearity* **35**, 1380 (2022).

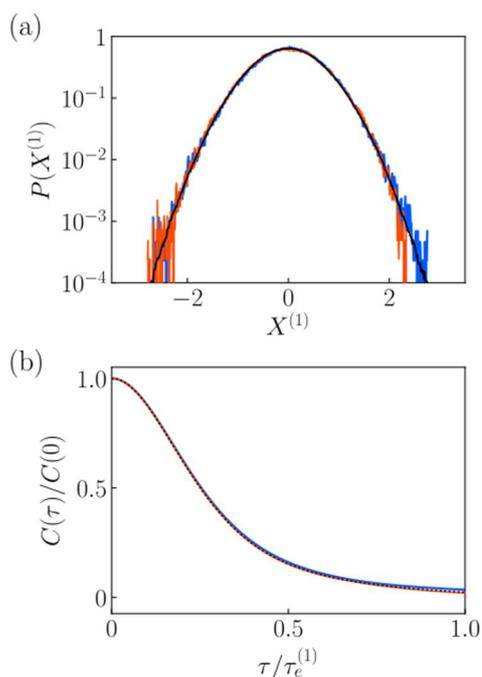


図4 SCSMのモデル化の性能評価。最低波数(最大スケール)のモードの(a)確率密度関数および、(b)二時刻自己相関関数(横軸はこのモードの特徴時間 $\tau_e$ で規格化している)。モデルによる得られた時系列から評価した値を赤線( $\ell_c = 6$ 、慣性領域)および、青線( $\ell_c = 12$ 、粘性領域)で示す。黒線が真値を表す。ここでは、正則化パラメタを $\beta = 10^{-5}$ としたが、 $\ell_c = 12$ の場合には $\beta = 0$ としてもモデルの性能は変わらない。

## 5. 主な発表論文等

〔雑誌論文〕 計9件（うち査読付論文 5件 / うち国際共著 0件 / うちオープンアクセス 3件）

1. 著者名 Mikito Konishi, Masanobu Inubushi, Susumu Goto	4. 巻 12
2. 論文標題 Fluid mixing optimization with reinforcement learning	5. 発行年 2022年
3. 雑誌名 Scientific Reports	6. 最初と最後の頁 14268
掲載論文のDOI（デジタルオブジェクト識別子） 10.1038/s41598-022-18037-7	査読の有無 有
オープンアクセス オープンアクセスとしている（また、その予定である）	国際共著 -
1. 著者名 Tomonori Tsuruhashi, Susumu Goto, Sunao Oka, Tsuyoshi Yoneda	4. 巻 380
2. 論文標題 Self-similar hierarchy of coherent tubular vortices in turbulence	5. 発行年 2022年
3. 雑誌名 Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences	6. 最初と最後の頁 20210053
掲載論文のDOI（デジタルオブジェクト識別子） 10.1098/rsta.2021.0053	査読の有無 有
オープンアクセス オープンアクセスとしている（また、その予定である）	国際共著 -
1. 著者名 藤野潤, 本告遊太郎, 後藤晋	4. 巻 41
2. 論文標題 円柱背後の乱流の生成機構	5. 発行年 2022年
3. 雑誌名 ながれ	6. 最初と最後の頁 53-56
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 無
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -
1. 著者名 鶴橋知典, 後藤晋, 岡温, 米田剛	4. 巻 41
2. 論文標題 乱流渦の階層の自己相似性	5. 発行年 2022年
3. 雑誌名 ながれ	6. 最初と最後の頁 386-390
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 無
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 犬伏正信, 後藤晋	4. 巻 41
2. 論文標題 3次元周期箱乱流の連続データ同化と軌道不安定性	5. 発行年 2022年
3. 雑誌名 ながれ	6. 最初と最後の頁 399-402
掲載論文のDOI (デジタルオブジェクト識別子) なし	査読の有無 無
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Yoneda Tsuyoshi, Goto Susumu, Tsuruhashi Tomonori	4. 巻 35
2. 論文標題 Mathematical reformulation of the Kolmogorov-Richardson energy cascade in terms of vortex stretching	5. 発行年 2022年
3. 雑誌名 Nonlinearity	6. 最初と最後の頁 1380-1401
掲載論文のDOI (デジタルオブジェクト識別子) 10.1088/1361-6544/ac4b3b	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 犬伏正信	4. 巻 85
2. 論文標題 「リザバーコンピューティング：時系列データの機械学習」	5. 発行年 2021年
3. 雑誌名 化学工学会誌「化学工学」	6. 最初と最後の頁 700
掲載論文のDOI (デジタルオブジェクト識別子) なし	査読の有無 無
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Masanobu Inubushi, Susumu Goto	4. 巻 102
2. 論文標題 Transfer learning for nonlinear dynamics and its application to fluid turbulence	5. 発行年 2020年
3. 雑誌名 Phys. Rev. E	6. 最初と最後の頁 43301
掲載論文のDOI (デジタルオブジェクト識別子) 10.1103/PhysRevE.102.043301	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

〔学会発表〕 計30件（うち招待講演 14件 / うち国際学会 4件）

1. 発表者名 後藤晋
2. 発表標題 発達した乱流中の秩序渦の階層
3. 学会等名 日本学術振興会二国間ワークショップ（招待講演）
4. 発表年 2022年

1. 発表者名 Susumu Goto
2. 発表標題 Application of Reservoir Computing to Turbulence
3. 学会等名 2nd US-Japan Workshop on Data-Driven Fluid Dynamics（招待講演）（国際学会）
4. 発表年 2022年

1. 発表者名 Susumu Goto
2. 発表標題 Hierarchy of coherent vortices in developed turbulence and its role in transport phenomena
3. 学会等名 6th Asia-Pacific Conference on Plasma Physics（招待講演）（国際学会）
4. 発表年 2022年

1. 発表者名 Susumu Goto
2. 発表標題 Data-driven turbulence modeling
3. 学会等名 The 31st International Toki Conference on Plasma and Fusion Research（招待講演）（国際学会）
4. 発表年 2022年

1. 発表者名 後藤晋
2. 発表標題 機械学習による乱流モデルの可能性
3. 学会等名 日本学術振興会 二国間交流事業『非平衡複雑流動現象に関するワークショップ』（招待講演）
4. 発表年 2022年

1. 発表者名 Susumu Goto
2. 発表標題 Interactions between turbulence and particles & Related topics
3. 学会等名 日仏二国間交流事業セミナー
4. 発表年 2023年

1. 発表者名 鶴橋知典
2. 発表標題 乱流渦の階層の自己相似性
3. 学会等名 日本流体力学会 年会2022
4. 発表年 2022年

1. 発表者名 松元智嗣
2. 発表標題 リカレントニューラルネットワークを用いた乱流モデリング
3. 学会等名 第36回数値流体力学シンポジウム
4. 発表年 2022年

1. 発表者名 本告遊太郎
2. 発表標題 乱流中の渦の階層とスケール間エネルギー輸送
3. 学会等名 日本流体力学会年会2022
4. 発表年 2022年

1. 発表者名 本告遊太郎
2. 発表標題 発達した乱流におけるパッシブスカラーの階層構造
3. 学会等名 第36回数値流体力学シンポジウム
4. 発表年 2022年

1. 発表者名 犬伏正信
2. 発表標題 3次元周期箱乱流における同期現象と軌道不安定性
3. 学会等名 日本流体力学会年会2022
4. 発表年 2022年

1. 発表者名 犬伏正信
2. 発表標題 3次元周期箱乱流の連続データ同化と軌道不安定性
3. 学会等名 研究集会「現象と数理モデル 2022」
4. 発表年 2022年

1. 発表者名 Masanobu Inubushi
2. 発表標題 Characterizing data assimilation in Navier-Stokes turbulence with transverse Lyapunov exponents
3. 学会等名 APS March Meeting 2023 (国際学会)
4. 発表年 2023年

1. 発表者名 犬伏正信
2. 発表標題 データ駆動型流体シミュレーションの限界と可能性についての一考察
3. 学会等名 東京大学生産技術研究所 シンポジウム:力学の未来「これからの流体シミュレーションに期待するもの」(招待講演)
4. 発表年 2023年

1. 発表者名 犬伏正信
2. 発表標題 リザバーコンピューティングの数理的側面とカオス力学系の時系列予測
3. 学会等名 第70回 応用物理学会 春季講演会, FS.1 フォーカストセッション「AIエレクトロニクス」(招待講演)
4. 発表年 2023年

1. 発表者名 後藤晋
2. 発表標題 乱流の物理・データ・モデル化
3. 学会等名 統計数理研究所「諸科学における大規模データと統計数理モデリング&諸科学における大規模・多様なデータを基盤としたデータ駆動型研究の萌芽・推進のためのワークショップ」(招待講演)
4. 発表年 2021年

1. 発表者名 後藤晋
2. 発表標題 複雑な流動現象の数値シミュレーション、データ解析、モデル化
3. 学会等名 オンラインセミナー「流れの複雑現象」(招待講演)
4. 発表年 2021年

1. 発表者名 後藤晋、本告遊太郎、藤野潤、小西幹人、米田剛、鶴橋知典、犬伏正信
2. 発表標題 乱流の普遍性に基づく転移学習
3. 学会等名 第2回プラズマインフォマティクス研究会 (招待講演)
4. 発表年 2021年

1. 発表者名 犬伏正信
2. 発表標題 リザーバーコンピューティングの転移学習
3. 学会等名 第3回先進的ながれ研究会(招待講演)
4. 発表年 2021年

1. 発表者名 M. Inubushi
2. 発表標題 Transfer learning for nonlinear dynamics and its application to fluid turbulence,
3. 学会等名 Dynamical Systems and Machine Learning 2021 (招待講演)
4. 発表年 2021年

1. 発表者名 犬伏正信
2. 発表標題 リザバーコンピューティングの数理とその応用
3. 学会等名 低次元モデルに基づく先進的流体制御研究会
4. 発表年 2021年

1. 発表者名 犬伏 正信、中谷謙介、本告遊太郎、後藤晋
2. 発表標題 機械学習を用いた2次元角柱後流の乱流場推定
3. 学会等名 第64回 自動制御連合講演会・低次元モデルに基づく先進的流体制御OS
4. 発表年 2021年

1. 発表者名 犬伏正信、中谷謙介、後藤晋
2. 発表標題 リザバーコンピューティングを用いた乱流の状態推定 ~データ駆動型乱流研究への力学系的アプローチ~
3. 学会等名 第37回生研TSFDシンポジウム(招待講演)
4. 発表年 2022年

1. 発表者名 中谷謙介、犬伏正信、本告遊太郎、後藤晋
2. 発表標題 機械学習を用いた時系列データからの乱流場推定
3. 学会等名 日本流体力学会 年会2021
4. 発表年 2021年

1. 発表者名 松元智嗣、犬伏正信、後藤晋
2. 発表標題 リザバーコンピューティングを用いた3次元周期箱乱流のモデル化
3. 学会等名 日本機械学会関西支部第97期定時総会講演会
4. 発表年 2022年

1. 発表者名 犬伏正信、後藤晋
2. 発表標題 非線形力学系のための転移学習と乱流への応用
3. 学会等名 日本物理学会 2020年秋季大会
4. 発表年 2020年

1. 発表者名 犬伏正信
2. 発表標題 リザバーコンピューティングの転移学習と乱流への応用
3. 学会等名 大阪大学MDSワークショップ「工学と数学の接点を求めて」(招待講演)
4. 発表年 2020年

1. 発表者名 犬伏正信、後藤晋
2. 発表標題 周期箱乱流のエネルギーカスケードに基づく転移学習:エネルギー散逸率の推定
3. 学会等名 第34回数値流体力学シンポジウム
4. 発表年 2020年

1. 発表者名 小西幹人、犬伏正信、後藤晋
2. 発表標題 強化学習を用いた流体混合の最適化
3. 学会等名 日本流体力学会 年会2020
4. 発表年 2020年

1. 発表者名 中谷謙介、犬伏正信、後藤晋
2. 発表標題 機械学習を用いた2次元後流乱流の状態推定
3. 学会等名 日本流体力学会 年会2020
4. 発表年 2020年

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-

6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
研究 分 担 者	犬伏 正信  (Inubushi Masanobu)  (20821698)	東京理科大学・理学部第一部応用数学科・准教授   (32660)	

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------