

機械学習による乱流のエネルギー散逸率の空間分布の予測

Inference of the spatial distribution of turbulent energy dissipation rate by machine learning

- 後藤 晋, 阪大基礎工, 豊中市待兼山町 1-3, E-mail : goto@me.es.osaka-u.ac.jp
 犬伏正信, 阪大基礎工, 豊中市待兼山町 1-3, E-mail : inubushi@me.es.osaka-u.ac.jp
 Susumu Goto, Osaka Univ., 1-3 Machinkaneyama, Toyonaka, Osaka
 Masanobu Inubushi, Osaka Univ., 1-3 Machinkaneyama, Toyonaka, Osaka

Using a machine learning method, we infer the spatial distribution of the energy dissipation rate of turbulence in a periodic cube. When the external force driving the turbulence is given, we may use, as training data, a time-series of the kinetic energy and its dissipation rate at a *low* Reynolds number to infer the energy dissipation rate at *higher* Reynolds numbers from the instantaneous value of the kinetic energy.

1. はじめに

非圧縮流体の乱流の統計を考える上で、単位質量あたりの運動エネルギーの散逸率 $\epsilon(\mathbf{x}, t)$ は中心的な量である。これは、乱流の小スケールの統計がエネルギー散逸率と流体の動粘性係数 ν で特徴づけられる（コルモゴロフの相似仮説）ためである。したがって、例えば、乱流の小スケールの運動のモデル化のためには、大スケールの運動の情報を用いて $\epsilon(\mathbf{x}, t)$ を表現する必要がある。このとき、テラーの散逸則、

$$\langle \epsilon \rangle \sim \langle K \rangle^{3/2} / \langle L \rangle \quad (1)$$

が出发点となる。ここで、 K は運動エネルギー、 L は乱流の流速の特徴長さ（積分長がしばしば用いられる）であり、これらは乱流の大スケールの運動を特徴づける。また、 $\langle \cdot \rangle$ は統計平均である。確かに、(1) は ϵ の平均値を大スケールの統計量で表現しており、また、この式は統計的に定常な乱流に対しては正しい。定常乱流では、大スケールにおけるエネルギーの注入率（あるいは、大スケールから小スケールに流れるエネルギー流束）の平均値と $\langle \epsilon \rangle$ が釣り合うためである。

ところが、(1) を瞬時値どうしの関係に焼きなおすことはできない。我々はこれまでに、周期境界条件下で定常外力に駆動される乱流のエネルギー散逸率の空間平均値 $\bar{\epsilon}(t)$ と $\bar{K}(t)$ や $\bar{L}(t)$ との関係を検討し、

$$\bar{\epsilon}(t) \sim \langle \sqrt{K} \rangle \langle L \rangle \bar{K}(t) / \bar{L}(t)^2 \quad (2)$$

がよい近似を与えることを示した⁽¹⁾。この表現 (2) は、風洞内の格子乱流などの減衰乱流でもよい近似を与える⁽²⁾（その場合、 $\langle \sqrt{K} \rangle \langle L \rangle$ は流入条件で置き換える）が、今のところ実験則に過ぎない。

実際のモデルでは、さらに進んで、瞬時のエネルギー散逸率（あるいはエネルギー流束）の空間分布 $\epsilon(\mathbf{x}, t)$ が必要となる。これらは $\bar{\epsilon}(t)$ の予測よりも一段難しい。 $\epsilon(\mathbf{x}, t)$ の確立したモデル化が存在しないことから分かるように、この予測を演繹的に行うことは易しくない。そこで本研究では、機械学習の手法を用いて、乱流中の大スケールの情報から $\epsilon(\mathbf{x}, t)$ の予測を試みる。

2. 考える系と機械学習

周期境界条件下で、定常外力に駆動される乱流を考える。この系の特徴のひとつは、外力が時間依存しないにもかかわらず、 $\bar{K}(t)$ と $\bar{\epsilon}(t)$ が大きく時間変動することである⁽¹⁾。このとき、後者の時間変化の位相は前者に対して積分時間程度だけ遅れる。これは、 \bar{K} と $\bar{\epsilon}$ がそれぞれ大スケールと小スケールの乱流の活発度を表し、また、エネルギーカスケードには積分時間程度の時間がかかるためである。

同じ外力に対して、 ν の値を変えて異なる（テラー長）レイノルズ数 (Re_λ) の直接数値シミュレーション

を実行する。このとき、周期箱を I 個の部分領域に分割し、それぞれの部分領域における $\epsilon(\mathbf{x}, t)$ と $K(\mathbf{x}, t)$ の局所空間平均値をそれぞれ $\epsilon^{(i)}(\mathbf{x}, t; Re_\lambda)$ と $K^{(i)}(\mathbf{x}, t; Re_\lambda)$ ($i = 1, 2, \dots, I$) と表す。本研究の目標は後者から前者を予測することである。

機械学習として、「リザーバ・コンピューティング」⁽³⁾ と呼ばれる教師付き学習を用いる。このとき用いる教師データは、ある Re_λ に対する $(K^{(i)}, \epsilon^{(i)})$ の長時間の時系列とし、その学習結果をより高いレイノルズ数における予測にも流用する。外力を固定すれば、慣性領域におけるエネルギーカスケードの動力学は流体の動粘性係数（したがって、 Re_λ ）には依存しないはずなので、より低い Re_λ の教師データを用いた学習の結果は、より高い Re_λ でも使えるはずである。

3. 結果と議論

$I = 1$ つまり、空間分割をせずに、 $\bar{K}(t)$ から $\bar{\epsilon}(t)$ を予測した結果を Fig. 1 に示す。ただし、 $Re_\lambda = 30$ の時系列データを教師データとして、(a) $Re_\lambda = 30$ および (b) 280 に対して、それぞれの $\bar{K}(t)$ から $\bar{\epsilon}(t)$ を予測した結果を示す。いずれもよい予測を与える。講演では、 $I > 1$ の場合の結果についても報告する。




Fig. 1: Inference (red line) of the energy dissipation rate of turbulence at (a) $Re_\lambda = 30$ and (b) 280. The blue lines are real data.

参考文献

- (1) Goto, S. and Vassilicos, J.C., Fluid Dyn. Res. 48 (2016) 021402.
- (2) Vassilicos, J.C., Ann. Rev. Fluid Mech. 47 (2014) pp. 95–114.
- (3) Jaeger, H. and Haas, H., Science, 304 (2004) pp. 78–80.