

深層学習を用いた異種乱流混合状態における 3次元速度場の空間構造推定

日大生産工 (院) ○麿嶋 祐樹 日大生産工 佐々木 真

1. 背景

磁化不均一プラズマ内でのダイナミクスは、プラズマ密度や温度の空間不均一性によって駆動される乱流によって支配されている。この乱流により粒子や熱の輸送が引き起こされる。プラズマの性能は、粒子源や熱源と、輸送のバランスによって決定づけられるため、輸送を観測する事が核融合プラズマを理解するうえで重要となる¹⁾。この輸送を直接計測するためには密度や温度等のスカラー場と同時に速度場揺動の計測が必要であるが、速度場揺動の計測には大規模な装置が必要であったり、様々な仮定が必要であるため、しばし困難である^{2),3),4)}。

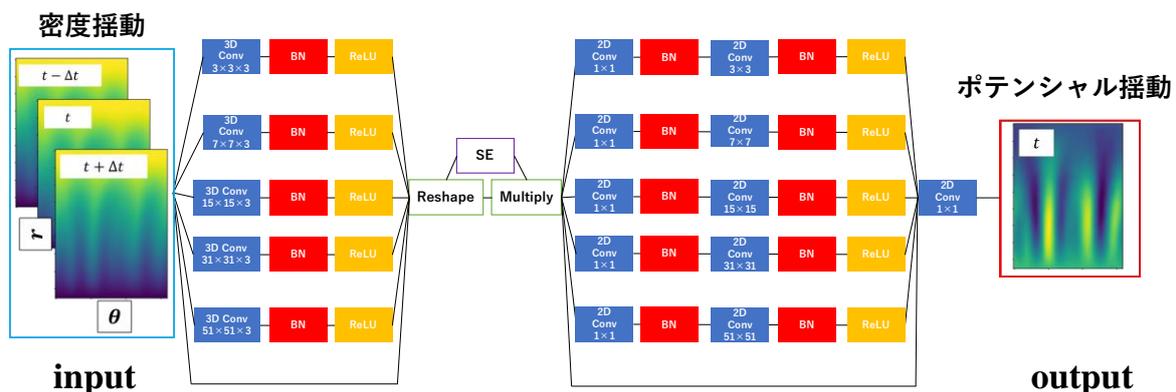
そこで、本研究ではプラズマ乱流シミュレーションと深層学習を用いて、計測容易な密度揺動から、計測が困難である速度場揺動を推定する。速度場揺動を推定するネットワークを構築し、そのネットワークを用いて、乱流駆動輸送の定量的推定が可能であるかも検討した。

2. 学習に用いる乱流データ

円筒形プラズマにおける簡約流体モデルに基づく乱流シミュレーションデータを学習対象とした。本コードは、Numerical Linear Device (NLD)と呼ばれており、抵抗性ドリフト波の非線形乱流状態を計算する事が可能である^{5),6)}。本研究では、磁場に垂直な面における2次元の密度揺動と静電ポテンシャル揺動を学習に用いた。速度場揺動はE×Bドリフトを仮定することで、静電ポテンシャル揺動から評価が可能である。

3. 乱流構造の推定手法

本研究では Fig. 1 に示されているような、マルチスケール畳み込みニューラルネットワーク⁷⁾を用いた。このネットワークは密度揺動(入力)から静電ポテンシャル揺動の空間分布(出力)を推定する。マルチスケール畳み込みニューラルネットワークでは空間的に局所的

Fig. 1 入力データとネットワーク構造⁹⁾

Spatial structure estimation of 3-D velocity field in heterogeneous turbulent mixed flow using deep learning

Yuki JAJIMA and Makoto SASAKI

な部分と大域的な構造を同時に検出するために、5つの異なるサイズのフィルターが使用されている： $3 \times 3, 7 \times 7, 15 \times 15, 31 \times 31, 51 \times 51$ 。入力画像のサイズは 86×64 ピクセルである。このように複数のフィルターを用いることで、様々な大きさの渦を検出することができる。これらのフィルターを用いて空間軸と時間軸の畳み込みを行う。

入力データは、密度揺動の時間方向に3フレーム連続の空間分布画像とし、出力データは、静電ポテンシャル揺動の空間分布画像とした。損失関数には平均二乗誤差を使用し、これを最小にするような最適化を行なった。今回のネットワークの最適化には Adam⁸⁾を用いた。学習データは training データ 280 枚、validation データ 40 枚、test データ 40 枚の 7:1:1 で分割を行った。ここで各データセットは、各物理量の平均が 0、標準偏差が 1 となるように正規化した。上記の条件で、training データの入力画像と出力画像との関係をネットワークに学習させ、予測では test データの入力画像から静電ポテンシャル揺動の空間構造を推定した。

4. 静電ポテンシャル揺動の時空間構造推定

静電ポテンシャル揺動の推定結果を Fig. 2 に示す。左がネットワークで推定された空間分布画像であり、右がシミュレーションで得られた空間分布画像である。両構造は径方向及び、周方向ともによく一致しており、時間発展を含めた相関係数は 0.98 である。このように高い精度での予測に成功している。

次に、推定精度の検証のためそれぞれの周方向スペクトルを求めた。静電ポテンシャル揺動を ϕ としたときの、周方向フーリエ分解は以下で表される。

$$\phi = \sum_m \phi_m e^{im\theta} \quad (1)$$

このとき m は周方向モード数、 θ は周方向角度

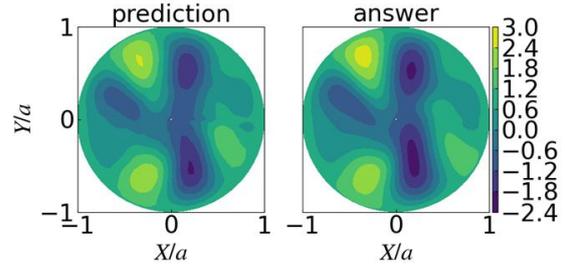


Fig. 2 静電ポテンシャル揺動の空間分布 (左) 推定結果 (右) シミュレーション⁹⁾

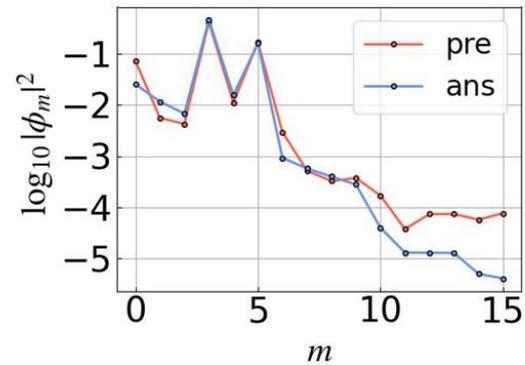


Fig. 3 静電ポテンシャル揺動の周方向スペクトル：赤線は推定された静電ポテンシャル揺動のスペクトルであり、青線はシミュレーションデータに対応する。⁹⁾

を表す。Fig. 3 に示すのは、半径 $r/a=0.58$ (r は半径、 a はプラズマ装置の半径を表す) における周方向モードスペクトルである。支配的となるモード数である $m=3, 5$ ではシミュレーションデータと予測データは良い一致を示しており、その相対誤差はそれぞれ 9%、5% である。

密度揺動を時々刻々と変化させたときの、静電ポテンシャル揺動の時間発展についても解析を行った。シミュレーションデータと予測データの周方向スペクトルに対する時間変化をそれぞれ $\phi_m^a(t)$ 、 $\phi_m^p(t)$ とし、コヒーレンス C_m と位相角 ψ_m を次のように計算した。

$$C_m = \frac{\langle \phi_m^p(t)^* \phi_m^a(t) \rangle}{\sqrt{|\phi_m^p(t)|^2 |\phi_m^a(t)|^2}} \quad (2)$$

$$\psi_m = \tan^{-1} \left(\frac{\text{Re}[\langle \phi_m^p(t)^* \phi_m^a(t) \rangle]}{\text{Im}[\langle \phi_m^p(t)^* \phi_m^a(t) \rangle]} \right) \quad (3)$$

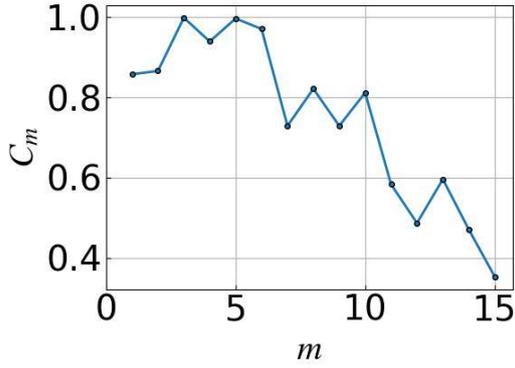


Fig. 4 推定結果とシミュレーションデータの
コヒーレンス C_m ⁹⁾

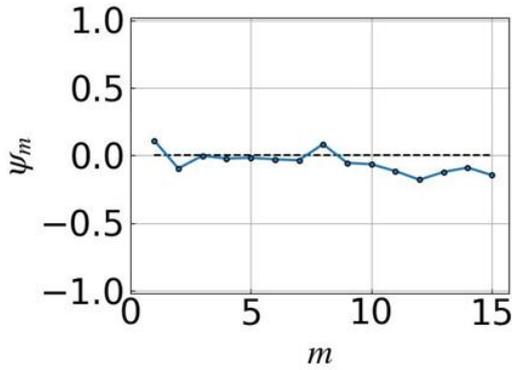


Fig. 5 推定結果とシミュレーションデータの
位相角 ψ_m ⁹⁾

ここで、 $\langle \rangle$ はアンサンブル平均、*は複数次共役を表す。Fig. 4 と Fig. 5 に、各モード数におけるコヒーレンスと位相角を示す。支配的なモード数 $m = 3, 5$ ではコヒーレンスはそれぞれ0.998 と 0.996 の値をとっており高い相関を示している。位相角はそれぞれ-0.0008 と-0.0157 の値であり、シミュレーションデータと予測データは時間的、空間的に良い一致を示している。

5. 乱流駆動粒子輸送の推定

推定された静電ポテンシャル揺動から粒子輸送を算出した。次のように粒子輸送 Γ は評価される。

$$\begin{aligned} \Gamma &= \langle \tilde{n} \tilde{v} \rangle \\ &= -\frac{1}{r} \sum_m \text{Im}[m n_m \phi_m^*] \end{aligned} \quad (4)$$

ここで、 \tilde{n} は密度揺動、 \tilde{v} は径方向速度場揺動であり、これは $E \times B$ ドリフトを仮定し、

$$\tilde{v} = -\frac{1}{r} \frac{\partial \phi}{\partial \theta} \quad (5)$$

静電ポテンシャル揺動で評価した。ここで、 $\langle \rangle$ は周方向平均、*は複数次共役、 $\text{Im}[\]$ は虚数成分を表す。Fig. 6 に示すのは、半径 $r/a=0.58$ での各モードが駆動する粒子輸送である。各モードからの輸送の総和は、93.1%の制度で推定されていることがわかった。このように推定した静電ポテンシャル揺動を用いて、粒子輸送の定量的な評価が可能であることを示した。

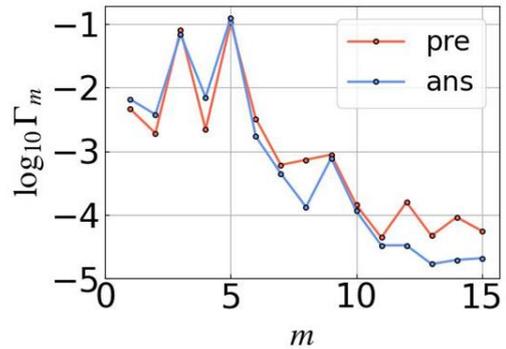


Fig. 6 各周方向モードが駆動する乱流粒子輸送：赤線は推定された乱流粒子輸送であり、青線はシミュレーションデータに対応する。⁹⁾

6. まとめ

本研究では、抵抗性ドリフト波乱流シミュレーションにより得られたデータに対して、マルチスケール畳み込みニューラルネットワークによる学習を行い、密度揺動から静電ポテンシャル揺動の推定を行った。得られた推定結果に対して、周方向スペクトルや相関係数を用いて推定精度の検証を行った。その結果、支配的な

モードに対して高い精度での推定が可能であることを示した。また、推定した静電ポテンシャル揺動から、粒子輸送の定量的な評価が可能であることを示した。

electrostatic potential fluctuations using multi-scale deep learning.", *Plasma Physics and Controlled Fusion*, (2023);, in press.

参考文献

- [1] Diamond, Patrick H., et al., "Zonal flows in plasma-a review.", *Plasma Physics and Controlled Fusion*, 47.5, (2005);, R35.
- [2] McKee, George R., et al., "Turbulence velocimetry of density fluctuation imaging data.", *Review of scientific instruments*, 75.10 (2004);, 3490-3492.
- [3] Ido, T., et al., "Spatial resolution of the heavy ion beam probe on LHD.", *Plasma and Fusion Research*, 2, (2007);, S1100-S1100.
- [4] Nagashima, Yoshihiko, et al., "Development of radially movable multichannel Reynolds stress probe system for a cylindrical laboratory plasma.", *Review of Scientific Instruments*, 82.3, (2011);, 033503.
- [5] Terry, P. W., "Suppression of turbulence and transport by sheared flow.", *Reviews of Modern Physics*, 72.1, (2000);, 109.
- [6] Sasaki, Makoto, et al., "Topological bifurcation of helical flows in magnetized plasmas with density gradient and parallel flow shear." *Physics of Plasmas* 24.11 (2017): 112103.
- [7] Ishikawa, Ryohtaroh T., et al., "Multi-scale deep learning for estimating horizontal velocity fields on the solar surface.", *Astronomy & Astrophysics* 658 (2022);, A142.
- [8] Kingma, Diederik P., and Jimmy Ba., "Adam: A method for stochastic optimization.", *arXiv preprint arXiv*;, 1412.6980, (2014).
- [9] Jajima, Yuki., and Sasaki, Makoto., et al., "Estimation of 2D profile dynamics of