

敵対的生成ネットワークに基づく 乱流部分計測から大域乱流構造の推定

日大生産工 ○風見 怜 日大生産工 佐々木 真

1. 背景

近年、エネルギー問題と環境問題を根本的に解決する手法として核融合発電が注目されている。しかしながら、実用化には様々な困難があり、その一つにプラズマの乱流輸送がある。核融合プラズマの極端な空間不均一性が乱流を駆動し、プラズマが拡散されることで、核融合達成のための高温・高密度状態が阻害される。そのため、乱流の制御や発生機構の理解が重要であり、様々な計測手法が開発されている。

代表的な乱流計測手法としてプローブ測定があるが、プラズマの内部はその高温特性のため中心部まで電極を挿入することができない。そのため、プラズマの中心部における各種物理量の詳細な計測は実現しておらず、装置壁面の限られた計測データをもとに、乱流構造を推定する必要がある。

本手法では外部装置からの局所的な計測可能物理量をもとに大域的な乱流構造を再構成する方法として、敵対的生成ネットワーク(GAN)を提案する。

2. 推定対象

長谷川・若谷方程式(HW)による密度揺動とポテンシャル揺動を推定対象とする。HWモデルは、磁場閉じ込めプラズマにおける密度不均一性に起因する静電的抵抗性ドリフト波乱流を記述する2流体モデルである。ここでは、密度勾配方向をx軸、磁場方向をz軸とし、y軸方向にドリフト波が伝搬するものとする。以下に、HWモデルの方程式を示す[1]。

$$\frac{\partial}{\partial t} \zeta + \{\varphi, \zeta\} = \alpha(\tilde{\varphi} - \tilde{n}) - D\nabla^4 \zeta \quad (1)$$

$$\frac{\partial}{\partial t} n - \{\varphi, n\} = \alpha(\tilde{\varphi} - \tilde{n}) - \kappa \frac{\partial \varphi}{\partial y} - D\nabla^4 n \quad (2)$$

ここで、 $\tilde{\varphi}$ および \tilde{n} はそれぞれポテンシャル揺動と密度揺動を表す。また、乱流の渦度 ζ は $\zeta \equiv \nabla^2 \varphi$ 、ポアソン括弧 $\{\alpha, \beta\} \equiv \frac{\partial \alpha}{\partial x} \frac{\partial \beta}{\partial y} - \frac{\partial \alpha}{\partial y} \frac{\partial \beta}{\partial x}$ で定義される。散逸係数はDで表す。

HWモデルの制御パラメータである拡散係数 α と密度勾配スケール κ は、 $\alpha = 0.1, \kappa = 1.0$ とし、この条件下で計算される密度・ポテンシャル揺動は乱流が支配的な構造を持つ[2]。計算された数値乱流場を基に実験での計測可能物理量を模して部分計測信号を生成し、未計測範囲の推定を行う。Fig.1の装置壁面に相当する数値乱流場の右端部を部分計測信号として推論モデルに入力し、推定領域の乱流信号を生成する。

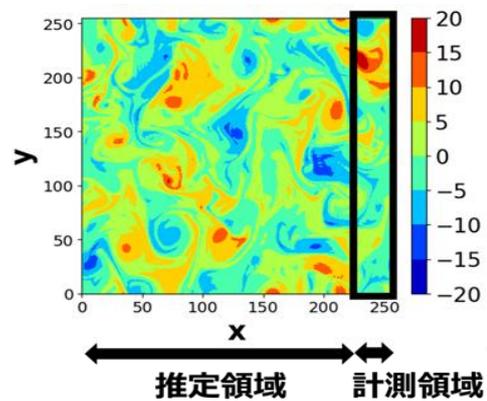


Fig.1 HW モデルによる密度揺動のスナップショット

3. 推定手法

推定手法として深層生成モデルである敵対的生成ネットワーク(GAN)を用いる。GANはGeneratorとDiscriminatorの二つのニューラルネットワークで構成され、Generatorは画像生成を行い、Discriminatorは生成画像の真偽判定を担う。両者は競い合う形で学習を進める敵対的な学習プロセスにより生成画像の精度向上を図るモデル構造を形成している。

本手法の学習フローをFig.2に示す。

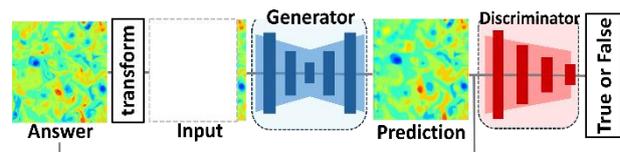


Fig.2 GAN のモデル構造

Estimation of Global Turbulence Profile from Partial Measurements Using Generative Adversarial Networks in Fusion Plasmas

Ren KAZAMI and Makoto SASAKI

まず、HWモデルの数値乱流場(Answer)を部分計測信号に変換してGeneratorに入力する。次にGeneratorが生成した乱流データ(Prediction)に対してDiscriminatorで真偽判定を行う。ここで、AnswerとPredictionの誤差を損失関数で評価し、DiscriminatorとGeneratorの学習パラメータを更新する。この学習プロセスを複数回繰り返し、学習後のGeneratorを乱流推定モデルとする。

本手法ではGANをベースアーキテクチャとするPix2Pixモデルを採用した。Pix2Pixは条件付きGANの一種で、二種類の画像間のドメイン変換を可能にするモデルである[3]。HWモデルから密度やポテンシャルの部分計測信号を生成し、部分計測ドメインから大域計測ドメインへと変換を行うことで大域的な乱流構造の推定を行う。

学習にはHWモデルで計算した13000枚の数値乱流場を、train:validation=9:1の割合で分割したデータセットを用いた。最適化手法にはRAdamを採用した。また、損失関数の設計には、基となる論文で採用されているAdversarial LossおよびL1 Lossに加えて、局所的な特徴を重視するPerceptual Lossを追加し、それらの重み付き和をモデルの損失関数とした。Perceptual Lossは学習済みのVGG19を特徴抽出器として、畳み込みによるAnswerとPredictionの双方の特徴量空間で損失を計算する[4]。

4. 乱流推定結果および評価

本手法での密度揺動の推定結果をFig.3に示す。

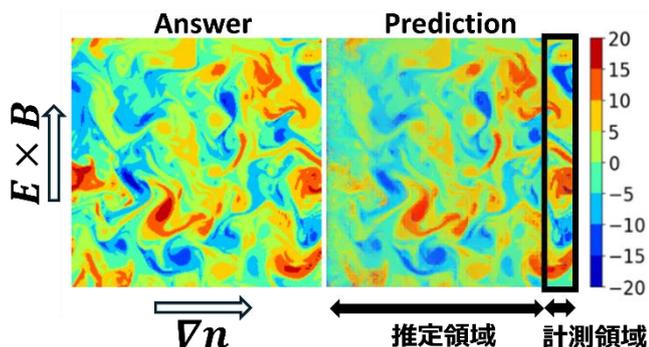


Fig.3 HW による数値解(左)と GAN による推定結果(右)

推定画像は元のデータの構造によく一致しており、計測領域から離れるほど推定が難しくなる。時間発展やポテンシャル揺動の推定に対しても同様の結果が得られた。

推定した乱流構造の周波数解析を行い、予測性能を評価した。評価指標として、波数空

間での相関係数であるコヒーレンスを用いた。コヒーレンス C_k は以下の式で示される[5]。

$$C_k = \frac{\langle R_k^a(\omega)^* R_k^p(\omega) \rangle}{\sqrt{|R_k^a(\omega)^*|^2 |R_k^p(\omega)^*|^2}} \quad (3)$$

R_k は評価対象の自己相関関数である。Fig.4では、推定方向に対応する波数空間 kx でのAnswerとPredictionのコヒーレンスの計算結果を示す。

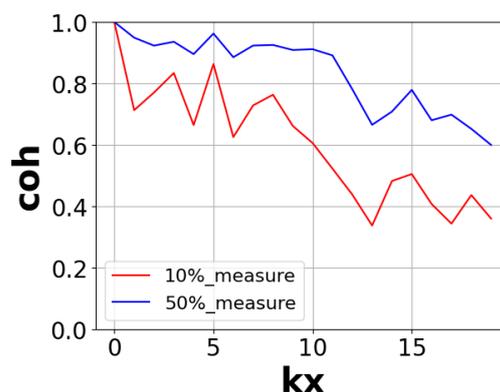


Fig.4 計測領域ごとのコヒーレンス計算結果

入力の部分計測範囲を元データの10%と50%としてそれぞれの性能を評価した。低周波数の大域的な乱流構造については、入力が生成分野の10%の場合でも相関係数0.7程度の推定性能が確認された。

5. まとめ

HWモデルで記述される静電抵抗性ドリフト波乱流に対して、深層生成モデルのGANを用いて部分計測を模した乱流データから大域乱流構造の推定を行った。得られた推定結果に対して波数空間での相関を計算することで、乱流構造の大域的な推定性能を評価した。その結果、低周波数の乱流空間では10%の計測領域で相関係数0.7程度の相関が得られた。

参考文献

- [1] M. Wakatani and A. Hasegawa, PoF, 27, 611, (1984)
- [2] R. Numata, et al, PoP, 14(10), 102312, (2007)
- [3] P. Isola, et al, CVPR, (2017), pp. 1125-1134
- [4] C. Ledig, et al, arXiv, arXiv:1609.04802v5, (2017)
- [5] Y. Jajima, et al, PPCF,65,125003(2023)