

人工知能・機械学習を用いた核融合プラズマの輸送研究

日大生産工 佐々木 真

1. 背景

磁場閉じ込め核融合プラズマは、中心温度が太陽コアの数十倍にもなる超高温状態であり、そのようなプラズマを高々数メートルの真空容器に閉じ込めるため極限的に温度・密度が空間不均一なシステムである。この温度や密度の空間勾配によって、乱流が生じ、乱流が駆動する輸送がプラズマの特性を支配している。そのため効率の良いプラズマ閉じ込めの実現には、乱流輸送の理解が必要不可欠である。

プラズマ乱流は、典型的には数 mm 程度の渦であるが、非線形的に数 cm~数 m 程度の流れや渦を生成したり、プラズマ全体を回転させたりする[1, 2]。このようにプラズマ乱流は多スケールの時空間ダイナミクスを伴う非常に自由度の高い系である。このようなプラズマ乱流の大域構造の観測は困難を極める。また、得られた乱流データは超大規模であり、従来の手法では、そこから物理的描像を抽出することが困難であった。

そこで、我々のグループでは、乱流シミュレーションや実験観測データ、数理モデリングと人工知能(Artificial Intelligence, AI)をはじめとした機械学習の様々な手法を組み合わせる事で、上述の課題に取り組んでいる。本予稿では、我々の取り組みの中から、プラズマ内部の乱流状態の推定手法についてと、機械学習による大規模自由度の低自由度に縮約手法に関する取り組みの幾つかを紹介する。

2. AI による乱流場の推定

核融合プラズマ内部は、密度や温度、流れが乱れた状態であり、粒子輸送や熱輸送を評価するためには、密度揺動と流れ揺動、温度揺動と流れ揺動のそれぞれを同位置で同時観測する必要がある。しかし、流れ揺動の直接観測は、大規模な装置が必要であったり、多くの仮定をおかなければならなかつたり、(1)汎用的な観測手法の開発が急務の課題となっている。また、観測点をプラズマ全域に配置することは非常に困難な為、(2)部分的な計測から全域を推定する必要もある。以下では、これらの問題に対

し、深層学習を用いた手法の開発の現状について述べる。

2-1. 計測可能量から流れ場の推定

基礎プラズマ装置における乱流シミュレーションによって得られた数値データを基に、手法開発を行った。基礎プラズマ装置では、密度揺動の観測は静電プローブ計測などにより、比較的容易である点に着目し、密度揺動から流れ揺動の推定を行う手法を開発した。畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)において、乱流の多スケール性を考慮すべく、学習する空間窓サイズを多數準備するマルチスケール CNN[3]を採用した

(Fig. 1 上図を参照)。ドリフト波乱流の密度揺動場を入力として静電ポテンシャル揺動(ここから流れ場の評価が可能となる)の推定に成功し、定量的に粒子輸送の議論が可能なレベルでの推定が可能となった[4]。さらに、本手法をケルビン・ヘルムホルツ乱流への拡張を行なっている[5]。

2-2. 部分計測情報からの大域構造推定

プラズマ乱流の大域計測は非常に困難であり、通常はプラズマ周辺部の乱流計測が精一杯である。そこで、プラズマの周辺部のみの情報から、内部の乱流状態の推定を可能とする手法として、敵対的生成ネットワーク(Generative Adversarial Network, GAN)を用いた手法を

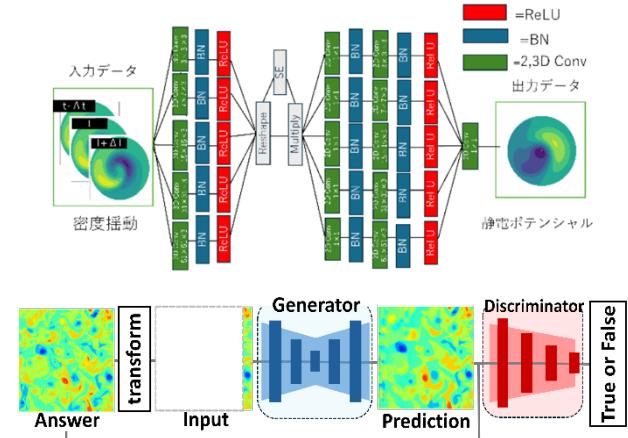


Fig. 1: 深層学習による乱流場の推定手法開発

上図：マルチスケール CNN による流れ場推定 [5]

下図：GAN による大域乱流場の推定 [6]

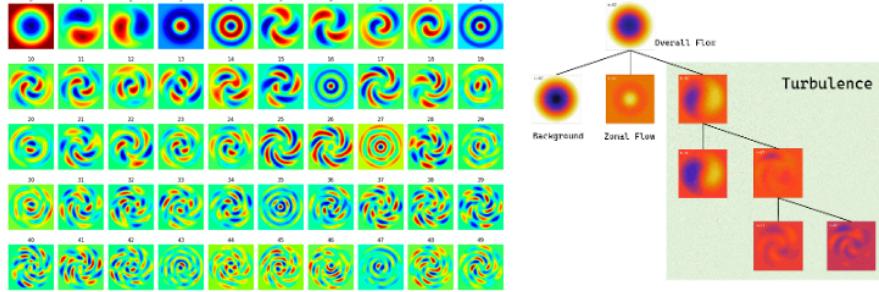


Fig. 2: 特異値分解による乱流階層構造の抽出。左図：特異値分解された空間モードの例、右図：空間モードのクラスタリングによる階層化

開発している。GAN は 2 つのニューラルネットワークで構成され、1 つは画像生成を行い、もう一方で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を得ることが可能である (Fig. 1 下図を参照)。乱流場の生成には、Hasegawa-Wakatani モデルに基づく、数値シミュレーションを用いた。得られたシミュレーションデータから部分計測を模擬した信号画像を生成し、GAN に投入する。GAN では、部分計測画像から大域的な乱流場の推定を行なった。推定された乱流場は、元データとの相関が 0.7 と非常に高精度な予測が可能である事が分かった。

3. 機械学習による乱流素過程の縮約

数値シミュレーションや実験などで得られるプラズマ乱流は、多スケール性を持つと共に、突発性・間欠性・遷移現象などを示すため、その全体像の系統的な解析は困難である。従来は、フーリエ分解に基づく解析が進められてきたが、これらの現象をフーリエ分解してしまうと、多くのモードが現れ、それらの素過程を理解することは困難である。そこで、我々はデータ駆動科学的にモードを直交分解する手法として、特異値分解に着目した。特異値分解は、データを表現するための直交基底をデータのみから得ることが出来る。さらに基底の直交性によって、分解された各モードのエネルギーやモード間相互作用の定量化まで可能となる [7]。

3-1. 多重場特異値分解

従来の特異値分解は、単一の物理量の分解に使用してきた。しかし、プラズマ乱流のような揺動場における粒子や熱の輸送を議論するためには、密度揺動、流れ揺動、温度揺動といった多種の物理量の揺動を解析する必要がある。従来手法のように、それぞれの物理量を別々に

分解すると、その分基底の数が多くなり、かつ基底の直交性を利用した解析が出来なかった。そこで、我々は多種の物理量を一つの大規模行列に置き換え、その後特異値分解するという手法 (多重場特異値分解) を開発した [8, 9]。この手法によると、複数の物理量を一つの空間基底で分解することが可能となり、物理量間の相関関係を系統的に調査することが可能となる。

3-2. 特異値モードのクラスタリング

特異値分解を行うとデータが巨大なほど多くの空間モードが得られる (Fig. 2 左図を参照)。この空間モードが持つ特異値の大きさに着目し、特異値をモード間の「距離」として、距離の順番にモードのクラスタリングを行う手法を開発した [10]。この手法では、任意の階層の数で乱流場を分解することが可能である。Fig.2 右図に階層構造の例を示す。

4. まとめ

我々のグループでは、乱流シミュレーションや実験観測データ、数理モデリングと AI や機械学習の様々な手法を組み合わせ、乱流の観測量の手法や、複雑データから物理素過程を抽出する手法を開発している。ポスターでは、これらの概略について紹介する。

参考文献

- [1] P. H. Diamond+, PPCF, 47, R35 (2005).
- [2] K. Ida+, NF, 54, 045001 (2014).
- [3] R. T. Ishikawa+, A.A., 658, A142 (2022).
- [4] Y. Jajima+, PPCF, 65, 125003 (2023).
- [5] 星野秀太, 生産工学部学術講演会(2024).
- [6] 風見怜, 生産工学部学術講演会(2024).
- [7] M. Sasaki+, PPCF, 63, 025004 (2020).
- [8] T. Kodahara+, PFR, 18, 1202036 (2023).
- [9] G. Yatomi+, PPCF, 65, 095014 (2023).
- [10] A. Okuno+, PFR in press (2024).