

核融合プラズマにおける高速な分布予測のための機械学習を用いた輸送モデリング

Transport modeling using machine learning towards fast profile prediction in fusion plasmas

成田絵美¹, 本多充¹, 仲田資季^{2,3}, 吉田麻衣子¹, 林伸彦¹, 竹永秀信¹
 E. Narita¹, M. Honda¹, M. Nakata^{2,3}, M. Yoshida¹, N. Hayashi¹, H. Takenaga¹




¹ 量研那珂, ² 核融合研, ³ 総研大

¹QST Naka, ²NIFS, ³SOKENDAI

核融合炉心プラズマは様々な物理現象によって支配されており、個々の物理現象を扱う物理モジュールを結合した統合型輸送コードが核融合炉の性能評価に用いられる。核融合炉の性能を左右する核融合出力は、炉心プラズマの密度と温度の分布に決定づけられるため、これらの分布予測に必要な輸送モデルは統合型輸送コードにおいて重要な役割を担っている。ITERを始めとするトカマクプラズマでは、密度と温度の分布を決める粒子と熱の輸送は乱流によって支配されているが、この乱流輸送の計算には非常に多くの計算コストを要するため、輸送モデルは統合型輸送コードの計算速度を低下させる原因となっていた。

輸送モデルは粒子束 Γ および熱流束 Q を算出する必要がある。 Γ と Q はジャイロ運動論コードを用いた第一原理計算によって詳細な乱流輸送物理を考慮しながら計算することができるが、莫大な計算コストを必要とする(10^3 以上の並列数で数日程度)。分布予測には、 Γ と Q を繰り返し計算しなければならないため($10^3 \sim 10^6$ 回)、通常は簡約化されたモデルが用いられる。しかしながら、簡約化モデルを用いた場合でも、分布予測には数時間から数日を要するため、更なる高速化のため

表1 世界の機械学習を用いた輸送モデル開発の特徴

	教師データを生成する簡約化モデル	機械学習モデルの結合対象
 米国 [1,2]	ジャイロ流体モデル TGLF	統合型体系 OMFIT ✓ 輸送以外も無矛盾にモデル化・計算
 欧州 [3,4]	ジャイロ運動論準線形モデル QuaLiKiz	高速輸送コード RAPTOR ✓ 実時間計算
 日本 [5,6]	物理機構分離モデル ✓ 分布形成機構の解析	統合型輸送コード TOPICS ✓ 輸送以外も無矛盾に計算

に、簡約化モデルの結果を再現する機械学習モデルの開発が米国、欧州、日本で進んでおり、ジャイロ運動論コードを用いた場合と比べて 10^{11} 程度の高速化に成功している。世界の機械学習モデルの開発は、機械学習の教師データを生成する簡約化モデルと、分布予測を行うために機械学習モデルと結合させる対象によって特徴づけられており(表1)、それぞれが特徴を活かしてITER計画等の核融合研究に貢献している。

米国と欧州の研究グループは、実験で観測された密度や温度の分布予測に広く用いられているジャイロ流体モデル TGLF とジャイロ運動論準線形モデル QuaLiKiz をそれぞれ用いて教師データを生成している。機械学習モデルは、ニューラルネットワークを利用し、TGLF および QuaLiKiz が算出する Γ や Q などを再現するように構築されている点で米国と欧州の研究は類似しているが、機械学習モデルと結合する対象が異なっている。まず、米国の機械学習モデル [1,2] は、輸送だけでなく、プラズマ周辺部の構造、磁場平衡、外部からの粒子源を無矛盾に扱うフレームワーク OMFIT に導入されている。OMFIT 内では、輸送以外の物理モデルに対しても機械学習が用いられており、これらの物理現象を無矛盾に扱いながら密度と温度の定常分布が時間発展を経ずに計算される。次に、欧州の機械学習モデル [3,4] は、分布の時間発展を計算する統合型輸送コード CRONOS や高速輸送コード RAPTOR に導入されている。特に RAPTOR は核融合炉の運転制御を目的とした輸送コードであり、機械学習モデルで乱流輸送を計算しながら、放電時間よりも短い時間で分布発展が計算できることを示している。

日本国内で開発が進む機械学習モデル [5,6] は、密度や温度の分布を予測するだけでなく、それらの分布形成機構を解析するツールとして構築されている。簡約化モデルには、乱流輸送を駆動する物理機構別に

Γ および Q を分解する物理機構分離モデルを用いている。 Γ を予測する場合、この物理機構分離モデルは $\Gamma = D(L_n^{-1} + C_T L_T^{-1} + C_P)$ として Γ を表現する。ここで D は粒子拡散係数であり、 Γ と D は規格化された値としている。右辺の括弧内の第一項は、熱力学的な力の一つである密度勾配 L_n^{-1} が駆動する拡散、第二・三項は、温度勾配 L_T^{-1} などに駆動されるピンチをそれぞれ表す。各項は係数 D 、 C_T 、 C_P を評価することによって定量的に求めることができるため、これらの係数を予測することが機械学習モデルの目的である。機械学習の教師データとなる係数の評価は、JT-60Uの実験データを対象として行われ、ジャイロ運動論コードによる数値計算と実験データを組み合わせることで、数値計算のみを使用した場合よりも評価に要する計算時間が削減されている。これにより教師データとして十分な評価結果が得られた。教師データは温度や密度の勾配など11の物理量と、11の物理量を1セットとしたときに対応する D 、 C_T 、 C_P の組み合わせで構成されており、教師データが持つ11の物理量と D 、 C_T 、 C_P の組み合わせを再現するようにニューラルネットワークが構築された(図1中右上)。

構築されたニューラルネットワークは輸送モデルとして、量研で開発された統合型輸送コード TOPICS や GOTRESS に導入されている。図1に TOPICS への導入の模式図を示す。まず、初期値となるプラズマの状態から、TOPICS はニューラルネットワークの入力となる11の物理量を輸送モデルに与える。次に、輸送モデルは11の物理量から係数 D 、 C_T 、 C_P を算出することで、拡散とピンチに関する項を分けながら Γ を TOPICS に渡す。

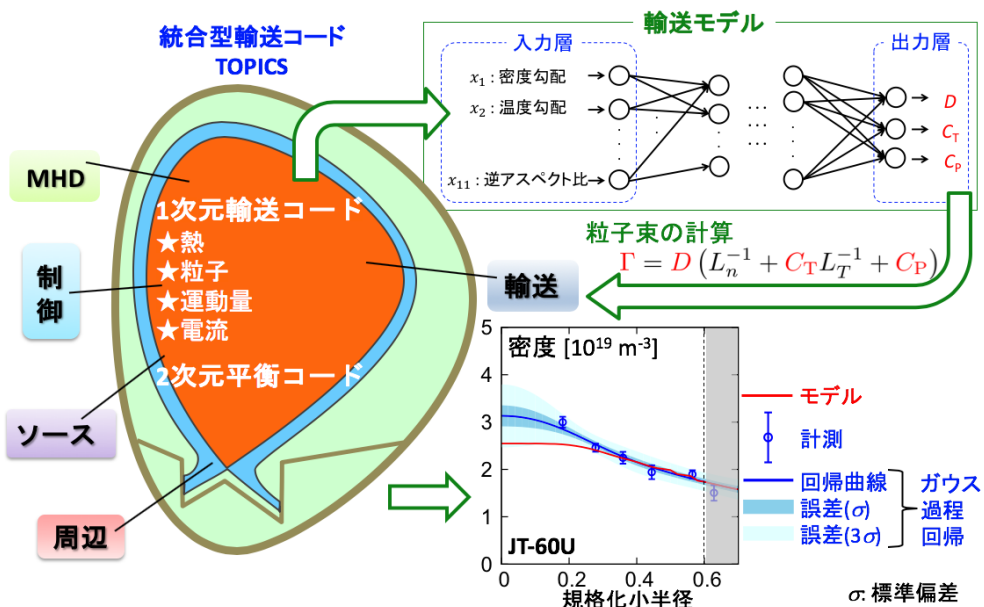


図1 機械学習を用いた輸送モデルと統合型輸送コード TOPICS の結合の模式図と、これらの結合によって計算される密度分布の例

TOPICS は受け取った Γ を使い、統合された輸送以外の物理モジュールと矛盾が生じないように輸送方程式を解き、次の時間ステップの密度分布を計算する。この繰り返しで得られる分布の時間発展を経て定常状態を予測することができる。機械学習の教師データに含まれない JT-60U のプラズマに対して予測結果は検証されており、概ね計測誤差の範囲内で機械学習モデルは密度分布を再現できている(図1中の右下)。また、本機械学習モデルの特徴である輸送機構の分離機能によって、実験結果から示された拡散とピンチの密度分布形成機構に対する影響を再現できることが確認されている。

上述のように世界の機械学習を用いた輸送モデルの開発は個々に特徴があり、それらを活かした研究活動が進められている。日本国内では、計算の高速化だけでなく、分布形成の物理機構の解析も可能な機械学習モデルの開発が行われているため、物理解明への適用という観点で研究を先導することが期待される。また、研究グループ間での情報共有などの国際協力の下で、今後も機械学習モデルの開発が進展すると考えられる。

[1] O. Meneghini *et al.*, Nucl. Fusion **57**, 086034 (2017).
 [2] O. Meneghini *et al.*, “Neural-network accelerated coupled core-pedestal simulations with self-consistent transport of impurities” *Proc. 27th Int. Conf. on Fusion Energy (Gujarat, India, 2018)*, TH/P6-16, IAEA, Vienna (2018).
 [3] J. Citrin *et al.*, Nucl. Fusion **55**, 092001 (2015).
 [4] F. Felici *et al.*, Nucl. Fusion **58**, 096006 (2018).
 [5] E. Narita *et al.*, Plasma Phys. Controlled Fusion **60**, 025027 (2018).
 [6] E. Narita *et al.*, “Gyrokinetic Modeling of Turbulent Particle Fluxes towards Efficient Predictions of Density Profiles” *Proc. 27th Int. Conf. on Fusion Energy (Gujarat, India, 2018)*, TH/P6-9, IAEA, Vienna (2018).