

機械学習を用いたJT-60SAのシナリオ開発 Scenario development for JT-60SA using machine learning

若月 琢馬
Takuma Wakatsuki

量研
QST

機械学習は近年目覚ましい発展を遂げており、核融合プラズマのシナリオ開発や制御システム開発に盛んに応用され始めている。機械学習を用いる利点としては(i)本来時間のかかるシミュレーションの高速化、(ii)複雑な実験的現象のモデル化が挙げられる。(i)としては乱流シミュレーションによる熱流束の予測をニューラルネットワークで近似するモデル(DeKANIS[1]、QuaLiKiz-NN[2])などが代表的な例である。(ii)としては、ディスラプションの予測[3]、放射崩壊の予測[4]などが代表的な例である。

JT-60SAでは高い規格化ベータ β_N を持つ先進プラズマの安定的な維持を目指している。安全係数分布を制御して磁気シアの小さくなる領域を作ることによって内部輸送障壁(ITB)を生成して、先進プラズマ運転を得ることが検討されている。ITBが生成されると自発電流が増加して、安全係数分布が影響を受けることになる。先進プラズマではプラズマ電流の大部分が自発電流となるため、安全係数分布及び圧力分布は自発的に構造を形成するようになる。そのため、外部加熱に対する安全係数分布、圧力分布の応答特性は強い非線形性を示す。

このような自律性の高い先進プラズマの時間発展の予測には、プラズマの圧力分布、電流分布の時間発展を自己無撞着に解くことのできる統合コードによるシミュレーションが有効であると考えられる。ただし現状、統合コードを用いてプラズマの時間発展を実時間で予測することはできない。そこで冒頭に述べた機械学習の利点を生かし、強化学習を利用して、統合コードを用いたシミュレーションに対する制御を事前に学習することで、先進プラズマにおける安全係数分布と β_N の複合制御を実時間で行うシステムを検討した。

強化学習とは、シミュレーションにおける試行錯誤を繰り返す中で制御システムを訓練す

る機械学習の一種である。ここでは、統合コードを用いたシミュレーションにおいて制御の試行錯誤を行って、ニューラルネットワークで構成された制御システムの訓練を行った。ニューラルネットワークによる制御出力は十分早く得られるため、訓練された制御システムは実験時に実時間で使用可能である。

制御の学習には数百万制御ステップを越える試行錯誤が必要なため、高速に計算可能な統合輸送コードRAPTOR[5]を利用した。RAPTORによるシミュレーションでは、計算条件の簡略化によって十分な試行回数を確保するため、加熱・電流駆動源ごとに固定された分布を仮定し、熱拡散係数分布は式(1)で示す関数形で与えられるモデルを利用した。

$$\chi_{ano}(s) = c_{ano} \rho q \left[\frac{a_{ic}}{1 + \exp(w_{ic}(d_{ic} - s))} + (1 - a_{ic}) \right] \quad (1)$$

これは、磁気シア s が小さくなる領域で輸送が改善するモデルである。

学習したシステムがシミュレーションと実験の間に存在するモデル化誤差に対してロバストに制御できるようにするために、学習時には熱拡散係数を決定する関数形のパラメータ(式(1)の a_{ic} 、 w_{ic} 、 d_{ic} 、 c_{ano} など)をランダムに変更した。それぞれ、 a_{ic} はITBの強さ、 w_{ic} はITBの広さ、 d_{ic} はITBが生成される磁気シア、 c_{ano} は全体的な異常熱輸送の大きさに関係する。これにより、様々な輸送特性を持つプラズマを模擬して学習することになる。ただし、あまりに広範な輸送特性に対して学習を行おうとすると、十分によい制御成績が得られなくなってくるのが分かった。特に、パラメータ a_{ic} はプラズマの応答特性に特に強く影響するため、幅広い範囲の a_{ic} に有効な制御を学習することは難しかった。図1は0.2-1.0の幅広い範囲の a_{ic} に対して学習したシステムを用いて、強いITBが生成されるパラメータ($a_{ic}=1.0$)に対して制御を行った結果である。このシステムは、安全係数の最小値 q_{min} と β_N を、青色で示す制御目標範囲の一定値に制




図1：幅広い輸送特性に対して学習したシステムによる q_{\min} と β_N の制御例。青色で示す目標範囲に制御はできているものの、長い周期で振動している。

御することを目指して訓練された。 q_{\min} と β_N は目標範囲の中で制御されているものの、一定値に制御はできておらず、10~20秒程度の周期で値が振動するような結果となっている。

この問題は、学習する際に与える a_{ic} の範囲を狭めることで回避できることが分かった。例えば図1の例では、学習の際に与える a_{ic} の範囲を0.9-1.0に限定することで、振動しない一定値に制御できるようになることが分かった。ただし、学習時に与えるパラメータ範囲を限定してしまうと、今度は実験のプラズマがどのような輸送特性を持つのか推定が難しい、もしくは輸送特性が時間的に大きく変化するような場合に適応可能なシステムを用意することが難しくなる。

そこで、輸送特性の範囲を狭めて学習を行った複数のニューラルネットワークを用意するとともに、制御システムの前段に輸送特性の推定を行うニューラルネットワークを用意した。このニューラルネットワークは計測データからRAPTORコードで使用している関数形のパラメータを推定するように学習したものであり、このニューラルネットワークによって推定された輸送特性(特に a_{ic})に応じて制御に使用するニューラルネットワークを切り替える。このシステムを用いて制御を行った結果を図2に示す。この結果では図1で問題になったような制御の振動は抑制されていることがわかる。この時、1.5秒から3.6秒までは負磁気シア分布形成前の制御について学習したシステム、3.7秒から4.3秒までは a_{ic} が0.6-0.9と比較的強いITBを持つプラズマについて学習したシステム、その後は a_{ic} が0.2-0.7の比較的弱いITBを持つプラズマに

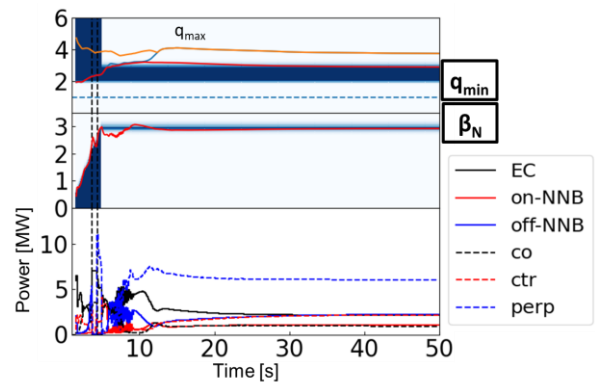


図2：推定した輸送特性に応じて制御に使用するニューラルネットワークを切り替えるシステムによる q_{\min} と β_N の制御例。青色で示す目標範囲の一定値に制御することができている。縦点線の時刻にニューラルネットワークが切り替えられている。

ついて学習したシステムに切り替えられて制御が行われている。

また、ここではRAPTORコードを用いて学習したシステムを、別の統合輸送コードTOPICS[6]を用いたシミュレーションに利用している。TOPICSでは中性粒子ビーム及び波動による加熱・電流駆動はプラズマパラメータの時間発展に合わせて計算され、より現実に近いシミュレーションである。熱拡散係数のモデルについてもCDBMモデル[7]を用いている。このように、2つのシミュレーションは異なる条件で実施されており、両者の違いはシミュレーションと実験の間にあるモデル化誤差を模擬するものと考え、強化学習によって構築した q_{\min} と β_N の複合制御システムが、有限のモデル化誤差がある状況に対しても適用可能であることがわかる。

以上のように、機械学習をもちいたJT-60SAの放電シナリオ及び制御システム開発として強化学習を用いた q_{\min} と β_N の複合制御システム開発が行われている。今後は本格的な加熱実験の開始に合わせて実験的な検証を行っていくことを検討している。

- [1] E. Narita et al., Nucl. Fusion 61, 116041 (2021).
- [2] A. Ho et al., Phys. Plasmas 28, 032305 (2021).
- [3] J. K. Harbeck et al., Nature 568, 526 (2019).
- [4] T. Yokoyama et al., PFR 16, 2402010 (2021).
- [5] F. Felici et al., Nucl. Fusion 58, 096006 (2018).
- [6] N. Hayashi and JT-60 Team, Phys. Plasmas 17, 056112 (2010).
- [7] M. Honda and A. Fukuyama, Nucl. Fusion 46, 580 (2006).