

強化学習を用いたプラズマ温度分布制御のJT-60U実験データを用いた検証 Validation of plasma temperature profile control system using reinforcement learning technique by experimental data of JT-60U

若月琢馬, 鈴木隆博, 大山直幸, 林伸彦
T. Wakatsuki, T. Suzuki, N. Oyama and N. Hayashi

量子科学技術研究開発機構, 那珂核融合研究所
QST, Naka Fusion Institute

トカマク型核融合原型炉で定常運転を行うためには、外部からの加熱・電流駆動に要するパワーを低減する必要がある。そのためには、内部輸送障壁 (ITB) の形成を通じてプラズマ電流の大部分を自発電流で駆動する方式が有望である。ITBを持つプラズマでMHD不安定性を避けるためには、規格化 β で表されるような大域的な圧力の指標だけでなく、安全係数の有理面などの位置での局所的な圧力勾配を適切に制御する必要がある。

そこでJT-60Uの実験において、荷電交換分光計測によるイオン温度計測データを用いて、 $q=2$ の有理面の付近に形成されるITBの内側と外側に位置する2つの計測点間のイオン温度差 (ΔT_i) のフィードバック制御が行われた。ITB形成時の ΔT_i の加熱パワーに対する応答特性は強い非線形性を示すため、フィードバック制御ゲインをイオン温度の関数とする制御が行われた[1]。ただしこの手法では、実験条件を変えるごとに新たにフィードバック制御ゲイン関数を最適化する必要があると考えられる。また、放電中に閉じ込め特性が変化してしまった場合には、同じフィードバック制御ゲイン関数で適切な制御が行えない可能性もある。

そこで本研究では、 ΔT_i の計測データと加熱パワー組み合わせから、その時刻における ΔT_i の応答特性が推定できると考え、 ΔT_i の計測データと加熱パワー、そして ΔT_i の制御目標値を入力すると、次時刻の最適な加熱パワーが出力されるシステムを、ニューラルネットワーク (NN、図1) を用いて構築することとした。

ニューラルネットワークの学習は強化学習と呼ばれる手法を用いて、統合輸送コード TOPICSを用いたシミュレーションでの試行錯誤から行う。弱いITBから強いITBまでに対応する熱拡散係数分布を持つプラズマに対して学習し、幅広い応答特性に対して適応した制御が行えるようになることを目指した。

学習の結果、図2に示す通り、ITBの強さが異なり、 ΔT_i の応答特性が異なるJT-60Uの2つの実験ショットを模擬したシミュレーションにおいて、 ΔT_i を適切に制御できることが示された。この結果から、あらかじめ多様な応答特性を模擬したシミュレーションに対して学習しておくことで、実験とは異なる輸送特性を用いて学習を行ったとしても、実験の輸送特性に適応して適切な制御を行えることが示された。

[1] M. Yoshida, et al., Fusion Eng. Des. **84**, 2206 (2009).




図1: イオン温度差 (ΔT_i) の適応的制御に用いるニューラルネットワーク (NN) の模式図




図2: JT-60UのITBを持つ2つのプラズマの輸送特性を実験的に解析し、それらの輸送特性を持つプラズマに対するイオン温度差 (ΔT_i) 制御をシミュレーションした結果。点線で示す ΔT_i の制御目標によく追従する制御が行えることが示された。