

# JT-60U におけるディスラプションの予知と 全状態探索を用いた物理的特徴の抽出

学生証番号 47-176092 氏名 横山 達也  
(指導教員 小川 雄一教授)

Key Words: Nuclear fusion, disruption, JT-60U, sparse modeling

## 1 序論

核融合発電に向けた磁場閉じ込めプラズマの研究は、外部コイルとプラズマ中を流れる電流によって磁場を作るトカマク方式が研究の主流である。トカマク方式の核融合プラズマに特有の現象として、プラズマ電流が瞬間的に消失し、蓄えられていたエネルギーが放出されるディスラプション現象がある。ディスラプションが発生すると、放出された熱・粒子束や誘導される電磁力が炉内の壁面や機器、真空容器やコイルに重大な損傷を与える恐れがあり、ディスラプションの制御はトカマク方式の核融合炉を実現するために克服しなくてはならない最重要課題の1つとされる。

しかし、ディスラプション現象には様々な要因があるとされ、その発生過程は未だ研究途上である [1, 2]。そこで、これまで蓄積されてきたプラズマ実験のデータと機械学習の手法を用いてディスラプション現象の発生予知を目指す研究が進められている [3, 4]。一方、ディスラプションの予知に用いるプラズマパラメータは、現象を十分説明できるものが選択されているとは限らない。そこで本研究では、機械学習を用いたディスラプション予知器モデルを作成し、スパースモデリングを導入してディスラプション現象に関連する物理パラメータを抽出し、予知性能の向上を目指す。

## 2 計算手法

### 2.1 サポートベクターマシン

サポートベクターマシン (SVM) [5] は教師あり機械学習モデルの一種である。本研究では、与えられた多次元の入力データ  $\mathbf{x}_i \in \mathbb{R}^d$  が2つのクラスのどちらに属するかを、対応するラベル  $\mathbf{y} \in \{-1, 1\}$  に従って分類する線形な境界超平面を求める線形 SVM を使用した。なお、線形 SVM における分類境界の方程式は  $\mathbf{w}^T \mathbf{x} + b = 0$  と記述され、線形 SVM を訓練するとは、この方程式の重み  $\mathbf{w} \in \mathbb{R}^d$  とバイアス  $b \in \mathbb{R}$  を決定することである。

### 2.2 スパースモデリング

スパースモデリングとは、様々な分野に高次元データに共通して潜在するスパース (疎) 性を利用し、効率的に最大限の情報を抽出することを目指す、データ駆動科学の枠組みの1つである。分類問題における変数選択では、単に個々の変数の分布を見て考えるのではなく、変数同士を組み合わせた際の効果を十分に考慮する必要がある。一方、パラメータの数が増えると変数の組合せの数が指数関数的に増えるという問題点が挙げられる。

本研究では、 $K$  スパース全状態探索法 (ES-K) [6] という手法によるスパースモデリングを導入した。ES-K では、最適なパラメータの組み合わせは  $K$  個のパラメータからなると仮定して、考えられるすべての組み合わせを網羅的に調べる。すなわち、 $N$  個のパラメータから  $K$  個をとる  ${}_N C_K$  個の組み合わせについて比較し、最適な組み合わせを求める。これを各  $K$  について実施することで、計算回数を削減できる他、異なる  $K$  での選択結果を比較することで組合せの構造を抽出することができる。

## 3 データセットの作成

本研究では、JT-60U で行われた高ベータプラズマ実験のデータを用いて、機械学習モデルを訓練、評価するためのデータセットを作成した。実験データは、プラズマ回転を利用して抵抗性壁モードの成長を抑制し、高いベータ値のプラズマを生成することを目的とした実験キャンペーンのものを用いた [7]。

データセットは、ディスラプション現象に関連する10個の巨視的なパラメータ ( $I_p, \beta_N, \beta_P, l_i, q_{95}, \delta, \kappa, f_{GW} = \bar{n}_e/n_{GW}, f_{rad} = P_{rad}/P_{input}$ ) とそのうち7個のパラメータの時間微分値、及び空間分布を持つ4個のパラメータ ( $V_t, T_i, \bar{\rho}, s$ ) とそのうち2個のパラメータの径方向勾配 ( $dV_t/dr, dT_i/dr$ ) の計23個のパラメータからなる。空間分布を持つパラメータは、いずれも  $q = 2$  有理面付近での値を使用した。

データは測定値と磁場平衡計算の値から作成され、5msおきに値を取得した。ディスラプションが発生した放

電については、ディスラプション発生時の 125 ms 前から 30 ms 前の値を、ディスラプションが発生していない放電については、基準時刻の 5 ms 前から 100 ms 前までの値を、それぞれモデルの訓練に用いた。

#### 4 計算結果

作成した予知器モデルは、各組合せを用いて訓練・評価された。評価は時系列的な環境を模擬して行われ、その基準には以下の 2 種類が用いられた。

$$\text{Prediction Success Rate (PSR)} = \frac{\text{Number of shots correctly judged as disruptive}}{\text{Total number of disruptive shots}}, \quad (1)$$

$$\text{False Alarm Rate (FAR)} = \frac{\text{Number of shots incorrectly judged as disruptive}}{\text{Total number of non-disruptive shots}}. \quad (2)$$

ある  $K$  に対応する ES- $K$  のある時刻での計算結果を縦軸に PSR、横軸に FAR をとった平面にプロットした 2 次元ヒストグラムである 2 次元状態密度図 (2D-DoS) に表現した。また、組合せ同士を比較するために、2D-DoS 内で最も理想的な予知機の性能 ( $PSR = 100\%$ ,  $FAR = 0\%$ ) に対応する点から、それぞれの組合せによる結果までの距離 (distance) を

$$\text{distance} = \sqrt{(100 - PSR)^2 + FAR^2}, \quad (3)$$

と定義した。この距離が小さいほど理想的な性能に近い良い性能のモデルであると言える。

図 1 に、各  $K$  で実施した ES- $K$ -SVM の、ディスラプションの発生する 30 ms 前時点での結果について示した。図 1 (a) は各  $K$  で理想的な性能からの距離が最も小さく、良い性能を示した組合せについて、その時の理想的な性能からの距離を示しており、7 個のパラメータの組合せを使用した場合に最も良い性能を示した。しかしその後では理想的な性能からの距離が横ばいであり、図 1 (b) に示した各組合せに含まれるパラメータを見ると、 $K = 5$




図 1: ES- $K$ -SVM の各  $K$  で最も良い性能を示した組合せの (a) 理想的な性能からの最小距離と (b) それぞれの組合せに対応するウェイトダイアグラム。

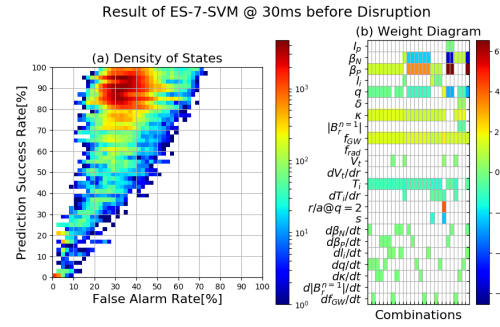


図 2: ディスラプションの発生時の 30 ms 前での ES-7-SVM の結果を示す (a) 2D-DoS と (b) 上位の組合せを表すウェイトダイアグラム。

から 8 では  $\beta_p$ ,  $\kappa$ ,  $f_{GW}$ ,  $T_i$ ,  $dq_{95}/dt$  の 5 個のパラメータが共通に含まれている。一方、図 2 に示したディスラプションの発生する 30 ms 前時点での ES-7-SVM の結果を見ると、最上位の組合せには、 $\beta_p$ ,  $q_{95}$ ,  $\kappa$ ,  $f_{GW}$ ,  $T_i$  の 5 個のパラメータが共通に含まれている。これらの組合せの重みとバイアスの値を平均した、ES-7-SVM で抽出された分類境界面の方程式を式 4 に示した。

$$1.32\beta_p - 0.288q_{95} + 1.57\kappa + 1.58f_{GW} - 0.889T_i - 1.61 = 0, \quad (4)$$

プラズマ制御における制約条件に、プラズマの状態に対応するデータ点から分類境界面からの距離を一定以上に保つことを加えることで、ディスラプションの危険性を考慮しながら所望のプラズマ性能を得るような制御への応用が期待される。

#### 5 結論

本研究では、機械学習を用いたディスラプション予知器モデルを作成し、ES- $K$  によるスパースモデリングを導入して入力パラメータの組合せの抽出を行った。その結果、適切なパラメータの組合せを選択することで予知性能を向上できることが示された。また、抽出結果からディスラプションの発生しやすいパラメータ領域を提案した。

#### 参考文献

- [1] A. H. Boozer. *Physics of Plasmas*, Vol. 19, No. 5, p. 058101, 2012.
- [2] T. Hender, et al. *Nuclear Fusion*, Vol. 47, No. 6, pp. S128–S202, 2007.
- [3] A. Murari, M. Lungaroni, E. Peluso, et al. *Nuclear Fusion*, Vol. 58, No. 5, p. 056002, 2018.
- [4] C. Rea, R. S. Granetz, K. Montes, R. A. Tinguely, N. Eidietis, J. M. Hanson, and B. Sammuli. *Plasma Physics and Controlled Fusion*, Vol. 60, No. 8, p. 084004, 2018.
- [5] C. Cortes and V. Vapnik. *Machine learning*, Vol. 20, No. 3, pp. 273–297, 1995.
- [6] Y. Igarashi, H. Takenaka, Y. Nakanishi-Ohno, et al. *Journal of the Physical Society of Japan*, Vol. 87, No. 4, p. 044802, 2018.
- [7] G. Matsunaga, K. Shinohara, N. Aiba, et al. *Nuclear Fusion*, Vol. 50, No. 8, p. 084003, 2010.