

機械学習を用いた HyperECR イオン源制御の準備状況 PREPARATION FOR MACHINE LEARNING-AIDED CONTROL OF HyperECR ION SOURCE

鎌倉恵太^{*A)}, 森田泰之^{B)}, 笠置歩^{C)}, 西隆博^{B)}, 岡直哉^{D)}, 中川真菜美^{E)},
小高康熙^{A)}, 中川孝秀^{B)}, 酒見泰寛^{A)}
Keita Kamakura^{*A)}, Yasuyuki Morita^{B)}, Ayumi Kasagi^{C)}, Takahiro Nishi^{B)}, Naoya Oka^{D)},
Manami Nakagawa^{E)}, Yasuteru Kotaka^{A)}, Takahide Nakagawa^{B)}, Yasuhiro Sakemi^{A)}
^{A)}CNS, the University of Tokyo, ^{B)}Nishina Center, RIKEN,
^{C)}Rikkyo Univ. AI, ^{D)}NICT, ^{E)}CPR, RIKEN

Abstract

CNS 14 GHz Hyper ECR ion source provides various ion beams to RIKEN AVF cyclotron. It has been continuously improved for more than 30 years since its installation, and its technology for supplying high-intensity multi-charged heavy ion beams has matured. On the other hand, there is still a difficulty with beam stability, especially when supplying metal beams. Even if a sufficient current of the beam is produced stably when the ion source is tuned, the current decreases over time, and beam production becomes unstable during long-term supply. Currently, the accelerator operator adjusts the parameters against the beam fluctuation to stabilize the beam. However, it is often necessary to interrupt the experiment to adjust the beam. To solve this problem, a stability control system of the ion source is currently under development using machine learning. The preparation status of the system will be discussed in this report.

1. 概要

東京大学 CNS では 14 GHz HyperECR イオン源を用いて理研 AVF サイクロトロンに様々なイオンを供給している。[1] 本イオン源では設置から 30 年以上にわたり改良が続けられており、その多価重イオンビームの大強度供給技術は成熟してきた。一方で特に金属ビーム供給時のビーム安定度に課題が残っている。

イオン源調整時に十分なビーム量が安定に出ているも、長期間の供給中にビーム量の低下やビーム生成の不安定化が起こる。現状ではビームの変動にあわせて加速器オペレータが細かくパラメータを調整することで安定化を図っているが、これには限界があり、実験を中断してビーム調整が必要になることも多い。この問題を解決するため、現在、機械学習を用いてイオン源の安定制御を補助するシステムの開発が進められている。今回の発表では、その準備状況に関して報告する。

2. HyperECR イオン源

本イオン源は、RF 周波数 14 GHz の ECR イオン源である。Figure 1 にその概略図を示した。一般に ECR イオン源において、ECR プラズマの状態を決める物理量は、電子密度と電子温度、イオンの閉じ込め時間である。一方でそれらを制御するための運転パラメータは、主にミラーコイル MC1(上流)と MC2(下流)2 系統の励磁電流、RF キャビティ条件調整用のプランジャ位置(固体試料使用時は試料位置)、イオン化ガスとサポートガスの流量制御用ニードルバルブの開度、マイクロ波の出力と多数存在する。また例えば、ガスの流量を上げると電子温度は下がるが電子密度は上がるなど、運転パラメータとプラズマの状態の物理量は一対一対応

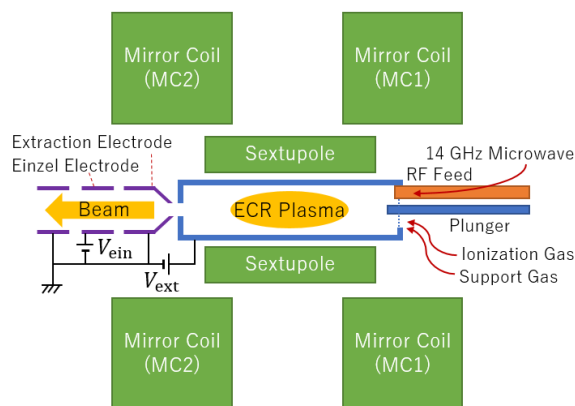


Figure 1: Schematic diagram of HyperECR ion source. Magnetic components are shown in green, the extraction system is in purple, geometrical elements affecting RF cavity condition are in blue and the RF feed is in orange.

していない。さらに本イオン源でそれらの物理量を直接観測することはできない。調整しながら得られる情報はビーム電流やプロファイル、プラズマ光などに限られるため、イオン源の制御は運転者は経験と勘に頼らざるを得ず、特に固体試料ビームなどは長期の安定制御も困難である。

本研究の目標は、運転者に依存せず長期運転時にも安定したビーム供給を可能にするような自動運転システムの実現である。今回はそれを機械学習のフレームワークを用いて構築するための準備を行った。

3. データ収集・制御系

データ収集及び制御系は理研仁科センター制御グループが開発した EPICS 制御システム [2] を利用しイ

* kamakura@cns.s.u-tokyo.ac.jp

オン源及び LEBT の運転パラメータ・測定データの収集と制御を行う。記録する値は、前述のイオン源制御パラメータに、マイクロ波の反射量、引き出し系のアインツェル電圧、ドレイン電流、引き出しチェンバの真空度、四重極電磁石と分析電磁石の電流、診断チェンバのスリット(上下左右)位置、ファラデーカップ電流値を加えた計 17 パラメータである。またプラズマ光の画像を記録するため、データ収集/制御端末にビデオカメラの映像を取り込めるようにした。

4. LightGBM を用いた決定木分析

運転パラメータのセットから目的のビーム量が予測できるようになれば、ビーム量を維持するような制御が可能になる。今回は勾配ブースティング決定木の機械学習フレームワークである LightGBM [3] を使い、既存の運転データを用いてモデルの訓練を試みた。サンプルとして利用したデータは本年 6 月の ${}^7\text{Li}^{3+}$ ビーム供給中に取得した 2 日間の運転データである。

特徴量として用いた変数は、時間 (time)、真空度 (vac)、上流ミラーコイル電流 (coil1)、下流ミラーコイル電流 (coil2)、サポートガス流量 (gas2)、リチウム坩堝位置 (rod_pos)、マイクロ波出力 (FwdPower)、マイクロ波反射量 (RefPower)、アインツェル電圧 (einzel_vol) の 9 パラメータである。ビーム供給中はファラデーカップを退避しているため、目的変数はビーム電流の代わりにイオン源状態の指標であるドレイン電流を用いた。

時系列データのうち前半の 90% を訓練と検証に利用し、後半の 10% でテストを行った。各運転パラメータからドレイン電流を予想させた結果を Fig. 2 に示す。このデータではビーム供給中ほとんど運転パラメータが変更されなかったため、回帰に必要なデータが不足しており、一部で予測精度が悪くなっている。

Figure 3 に示した特徴量の重要度をみると、時刻と真空度が支配的である。これはほとんど時刻による真空度の変化のみがドレイン電流を決めていたことを意味している。以上から、モデルの予測精度を上げるには各運転パラメータを大きく振ってモデルを訓練するた

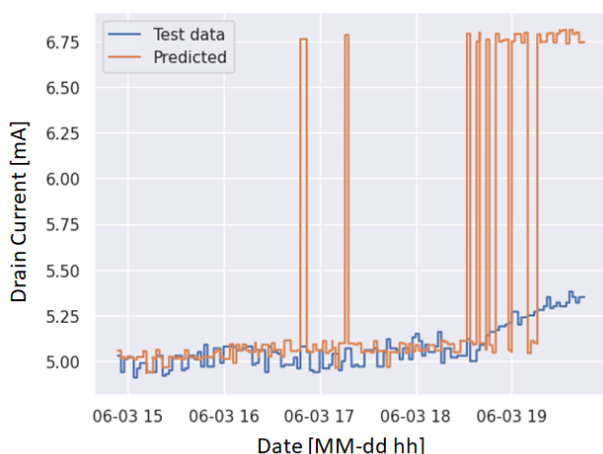


Figure 2: Measured drain current (marked as Test data) and the one predicted by the LightGBM model (marked as Predicted).

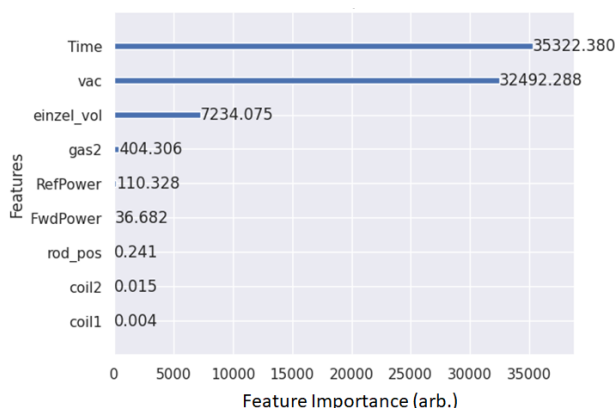


Figure 3: Feature importance of the trained model.

めのイオン源単独実験が必須であることがわかった。

5. プラズマ画像データの活用

プラズマ光の色とパターンは特に金属イオンビームの生成に重要な指標である。 ${}^7\text{Li}^{3+}$ の調整直後と供給終了時 (2 日後) のプラズマ画像を Fig. 4 に示した。供給終了時はプラズマが薄くなり、ビーム量も減少している。将来的には画像をそのまま機械学習モデルに入れることで、金属イオンビームの長期安定供給の実現を目指す。




Figure 4: Plasma images; right after tuning and after 2 days of beam production. (Left to right.)

6. 考察とまとめ

機械学習による HyperECR イオン源の制御を目指し、これまでにデータ収集・制御系の整備及び、勾配ブースティング決定木を用いたデータ分析を行った。機械学習モデルの訓練のため、各パラメータを振って運転を行い、教師データを蓄積する実験を予定している。今後はイオン源の長期安定性を向上させる自動運転を最終目標として研究開発を進めていく。

参考文献

- [1] K. Suda *et al.*, Proceedings of the 20th PASJ Meeting, TWSP12 (2023).
- [2] M. Nishimura *et al.*, Proceedings of the 13th PASJ Meeting, MOP099 (2016).
- [3] G. Ke *et al.*, Advances in Neural Information Processing Systems, 30, pp. 3146 – 3154 (2017).