

機械学習を用いたイオン源制御手法の開発

DEVELOPMENT OF ION SOURCE CONTROL METHOD USING MACHINE LEARNING

森田 泰之^{#, A)}, 福田 光宏^{A)}, 依田 哲彦^{A)}, 神田 浩樹^{A)}, 畑中 吉治^{A)}, 斎藤 高嶺^{A)},
田村 仁志^{A)}, 安田 裕介^{A)}, 鷲尾 隆^{B)}, 中島 悠太^{C)}, 岩崎 昌子^{D)}, KOAY HUI WEN^{A)},
武田 佳次郎^{A)}, 原 隆文^{A)}, 莊 浚謙^{A)}, ZHAO HANG^{A)}
Yasuyuki Morita^{#, A)}, Mitsuhiro Fukuda^{A)}, Tetsuhiko Yorita^{A)}, Hiroki Kanda^{A)}, Kichiji Hatanaka^{A)}, Takane Saitou^{A)},
Hitoshi Tamura^{A)}, Yusuke Yasuda^{A)}, Takashi Washio^{B)}, Yuta Nakashima^{C)}, Masako Iwasaki^{D)}, Hui Wen Koay^{A)},
Keijiro Takeda^{A)}, Takafumi Hara^{A)}, Tsun Him Chong^{A)}, Hang Zhao^{A)}

^{A)} Research Center for Nuclear Physics, Osaka University

^{B)} Osaka City University

^{C)} Institute for Dataability Science, Osaka University

^{D)} Department of Reasoning for Intelligence, Osaka University

Abstract

In an ion source, various factors influence each other. Therefore, when operating the ion source, it is necessary to optimize and adjust various parameters such as the incident power of RF, the RF tuner, the flow rate of gas, and the electromagnet of the transportation line while observing the state of the beam. Since this adjustment is made by relying on the experience of the operator, the quantity, quality, and adjustment time of the beam are likely to vary depending on the operator. Therefore, this time, we have developed a control method that applies machine learning. This time, we specialized in maximizing the beam intensity, and succeeded in measuring a 0.4 mA $^4\text{He}^{2+}$ beam on the Faraday cup, which is the same as the maximum value operated by human.

1. はじめに

ECR イオン源ではガス圧や RF Power、印加電圧など、様々な要素が相互に影響しあっている。これらのパラメーターを毎回同様に設定したとしても、内部のプラズマ状態などが正確に再現されるとは限らないため、引き出されるビーム量・質を向上させるためにその都度調整を行う必要がある[1]。現状、これらの調整は人の経験則をもとに行われている。この調整方法では調整者の癖や感覚に依存する部分があり、調整者によってビームの量や質、調整にかかる時間などが異なる可能性がある。また、イオン源の性能を最大限に引き出すためには、イオン源の性質を正しく理解することが重要である。そのためには複数のパラメーターの相関を調べ、それに基づいた調整を行う必要がある。そこで今回、調整者に依存しない自動制御の実現、並びに複数のパラメーターの相関を調べるために必要なデータ解析に向けて機械学習を応用したイオン源制御手法の開発を行った。本発表では開発の現状及びその結果に関して報告を行う。

2. 機械学習

機械学習と一概に言っても現在、様々な分野で注目されている深層学習など、様々な手法がある。それぞれに特徴があり、得手不得手があるため、どのような手法を選択し、活用するかが非常に重要である。その中で本研究では“強化学習[2]”と“ベイズ最適化[3]”という二つの

手法を組み合わせた制御手法の開発を行った。

強化学習は機械(Agent)が自ら行動(イオン源では制御パラメーターの変更など)を起こし、その結果環境(イオン源では真空度や RF Power、ビームの量・質など)がどのように変化したかを観測する。その観測結果から報酬を決定し、その行動の良し悪しを学ぶことができる。強化学習では深層学習を利用(深層強化学習)することで複雑な問題を解くことができる。また、学習が完了すれば最適なパラメーター値に調整するのみならず、調整の順序や変化量なども学習することができる。一方で学習に必要なデータ量が非常に多く、環境が大きく変わってしまうと再度学習しなおす必要がある。そのため、シミュレーションができないイオン源では実際に動かし、データを得るまでに必要な時間とパラメーター空間を考慮して利用する必要がある。

一方でベイズ最適化は実際に得られたデータをもとに分布を予想し、最小値(最大値)を探すことができる。時系列を考慮することができないため、強化学習に比べて複雑な問題には不向きである。また、その都度データを集める必要があるため、学習済みの強化学習よりも最適化に時間がかかってしまう可能性が高い。しかし、少ないデータ数で複数のパラメーターの相関を予想し、最適化することができ、予想関数に誤差を考慮するためローカルミニマムに囚われにくいという利点がある。

実際イオン源を運転する際にはデータ数を集めるのが困難な場合や状態が変動し、学習済みの機械学習がうまく動作しなくなってしまう場合が予想される。そこで今回の研究ではこれらの手法を組み合わせることで、それぞれの欠点を補い、強みを生かせるような制御手法の開

[#] morita16@rcnp.osaka-u.ac.jp

発を行った。

3. 実験用テストベンチ

機械学習を利用した制御手法のテストを行うために今回、ECR イオン源(NANOGAN)、偏向電磁石、収束用四重極電磁石(二台)、ペPPERポット型エミッタンスモニター(PPEM)[4]、ファラデーカップからなるテストベンチを組んだ。(Fig. 1)



Figure 1: Schematic of the test bench.

3.1 調整可能パラメーター

今回のテストベンチで調整可能なパラメーターを Table 1 に示す。

Table 1: List of Adjustable Parameters

パラメーター	調整対象	最大値	最小値	刻み
RF Power (信号源)	デジタル 制御	-11.0 dBm	-14.0 dBm	0.1 dBm
RF チュー ナー	モーター 回転数	0 step	32000 step	100 step
Gas Valve	モーター 回転数	0 step	32000 step	100 step
偏向電磁石	モーター 回転数に よる可変 手抵抗値	0 step	67000 step	100 step
四重極電磁 石	Arduino (マイコン) 出力値	0 step	255 step	1 step

RF は信号源から発生させたものを Power Amplifier で増幅し、プラズマチェンバーへ入射する。今回の調整では RF Power の制御として信号源の値を調整し、Power Amplifier の増幅率は固定として行った。今回の実験では信号源の値を Table 1 に示すとおりに変化させることでプラズマチェンバーへの入力波は 4 W から 8 W の間で Power が変化する。

RF チューナーは手動でつまみを回すことで±5 mm の出し入れが可能となっている。つまみにモーターを取り付け、その回転量を制御することで調整を行っている

(Fig. 2)。また、ガスバルブに関しても同様にニードルバルブのつまみにモーターを取り付け、その回転量を制御




Figure 2: RF tuner control system by motor control.

することでバルブの空き具合を制御している。

偏向電磁石の制御では電源に接続した可変抵抗の抵抗値を変えることで流れる電流量を調整している。可変抵抗の抵抗値は RF チューナーや Gas Valve と同様にモーターの回転数に応じて変動するように設計しており、モーターの回転数を制御することで電流値を調整することが可能である[5]。一方、収束用四重極電磁石はマイコンの一種である Arduino の出力時間を 0 から 255 の 8bit で制御し、コンデンサ等を使って電圧出力に変換 (Fig. 3)している。出力電圧を 0 V から 10 V の間で変化させることで電源の出力をコントロールし、最大 20 A の電流を流すことができる[5]。




Figure 3: Arduino output conversion circuit.

3.2 観測パラメーター

機械学習では情報の欠如が多いと正しく学習できない可能性があるため、直接の制御が不可能なパラメーターの観測も行っている。観測を行っているものは以下の通りである。

1. RF 入力波(Power Amplifier 増幅後)
2. RF 反射波(Power Amplifier 増幅後)
3. プラズマチェンバー空冷の排気温度
4. 室温
5. 真空度
6. 引き出し電極印過電圧
7. 引き出し電極のドレンカレント
8. ビーム電流量

これらのデータを使って機械学習を行った。

4. 結果

今回の実験ではエミッタンス測定は行わず、ビーム電流量を最大化する調整が可能であるかの実験を行った。今回の実験では $^4\text{He}^{2+}$ ビームを、引き出し電圧 20.0 kV で実験を行った。

4.1 RF チューナーの調整

今回のテストベンチでは RF チューナーは経験則から抜き差しする過程の時系

列データが重要になることが分かっている。また、チューナーのみの調整を行うことで十分な量のデータ数を稼げることから強化学習を用いて制御する手法の開発を行った。

今回は tensorflow と keras-rl2、OpenAI gym を使って中間層 4 層の強化学習(Deep Q-Network, DQN)[2]を組んだ。

今回の設計では RF 反射波の Power を測定し、その反射波の信号が 0.25(4 W 相当)を下回った際に+1 の報酬が与えられ、設定範囲外に出たときに-1 の報酬が与えられるようになっている。ただしこの反射波の測定ではキャリブレーションが不十分であるため、W 冠山に関しては絶対値ではなく相対的な評価を公的として扱っている。調整の一例を Fig. 4 に示す。値の変動ではなく、最終的な設定値に到達したか否かを報酬の判断基準にしたことで、途中で一度反射波が大きくなることがあっても最終的に小さくなるような行動をとることができていることが分かる。




Figure 4: Number of RF tuner control actions and transition of reflected waves.

4.2 輸送電磁石の調整

ビーム電流量を正しく判断するためには偏向電磁石と二台の収束用四重極電磁石を正しく調整する必要がある。イオン源のように低エネルギーのビーム輸送の場合には磁場はそこまで大きくないためヒステリシスを考えなくてもよいこと、大きな変更は不要である場合が多いことからベイズ最適化による調整を検証した。

ビーム電流量を最大化するように偏向電磁石、二台の四重極電磁石の電流値を調整するように Python 用のベイズ最適化のライブラリである GPyOpt[6] を用いてベイズ最適化のアルゴリズムを作成した。この時、Acquisition function は分散を考慮した際に最小値(最大値)となる点を探索する Lower Confidence Bound (LCB)を採用した。

一般的に偏向電磁石はビームの引き出し電圧が一定であれば偏向電磁石の電流量も一定でよいが、今回はアライメントが 1 mm ほどずれている可能性があったため、 ± 200 step 分だけ微調整の余地を残した。収束用の四重極電磁石に関しては上流側が垂直方向の収束、下流側が水平方向の収束マグネットとなっており、どちらも最大 20 A の電流値が流せるようになっている。

ベイズ最適化による電磁石の調整回数とビーム量の推移を Fig. 5 に示す。今回の調整では前提条件として変更電磁石に約 12 A の電流を流すと $^4\text{He}^{2+}$ ビームがファラデーカップに入射できるという事前知識のみを活用しており、輸送計算の結果などは使用していない。にもかかわらず、電磁石を自動で調整し、17 回目の磁場調整時にはすでにおおよその調整が終わりそのあとより良い解がないかの微調整を行えていることが分かる。




Figure 5: Number of electromagnet control actions and transition of beam intensity.

4.3 RF Power 及び Gas Valve の調整

最後に RF Power とガス流量の調整に関して試験を行った。今回の実験では、先述の通り RF Power として RF 信号源の Power を調整し、Power Amplifier の増幅率は一定とした。また、本実験ではバッファータンクにヘリウムガスをため、ニードルバルブの開閉でガス流量を制御している。そのため、本実験ではガス流量の直接的な観測・制御ではなく、ニードルバルブの開閉量を制御している。

RF Power と Gas Valve の調整を行うため、その都度 RF チューナーを調整する必要があること、ガスバルブの開閉後に真空度が安定するまでに時間がかかることからデータ数をためにくいと考え、ベイズ最適化による調整を検証した。ベイズ最適化のライブラリは磁場調整の際と同様に GPyOpt を使用し、Acquisition function には LCB を採用した。また、今回の実験では、RF Power と Gas Valve の設定値を変えるごとに前述の方法で RF チューナー、電磁石を調整しなおしてからビーム電流量を測定している。

RF Power と Gas Valve の調整回数とビーム量の調整中の最高値の関係を Fig. 6 に示す。今回の実験では Acquisition function として LCB を採用しているため、ビーム電流量には-1がかかっている。同様の実験を日を改めて 5 回行ったが、すべて 20 回から 40 回程度の調整で 0.4 mA 程度のビーム電流量を引き出すことに成功

した。

また、ベイズ最適化によって予測された RF Power と Gas Valve の調整値とビーム電流量の関係の様子を Fig. 7 に示す。Figure 7 中の丸い点は測定箇所である。また、関数は電流量に -1 をかけた後、 -1 から $+1$ までの間になるよう規格化されているため、カラーバーの値が直接的なビーム電流量を示していないが、調整パラメーターとビーム電流量増減の相関を見ることができる。この結果から今回の実験で使用した NANOGAN では RF Power はビーム電流量に大きな影響を及ぼしておらず、Gas Valveの開閉量、すなわちガスの流量が大きく影響していることが分かる。




Figure 6: Changes in the number of adjustments of RF power and gas valve and the record highs of beam current. (Beam current multiplied by negative sign).




Figure 7: Predicting the relationship between RF Power and Gas Valve adjustment and beam amount by Bayesian optimization. (The beam amount has a negative sign.)

5. まとめと展望

今回、機械学習を用いてビーム電流量を最大化する RF Power、Gas Valve、RF チューナー、輸送電磁石の調整システムの実証を行い、ビーム電流量を 0.4 mA 程度安定して引き出すことに成功した。発表者が調整を行った際にも 0.4 mA 程度が限界であったため、ビーム電流量の最大化という点においては有用な手法であると考えられる。

しかし、実際の運転では加速器のアクセプタンスにマッチしたビームの供給が重要であるため、位相空間分布を含めた調整が必要になる。そのため、今後はエミッタンスモニターを使用した調整手法の開発を行う必要がある。

参考文献

- [1] O. Tarvainen *et al.*, “Plasma diagnostic tools for ECR ion sources—What can we learn from these experiments for the next generation sources”, Rev. Sci. Instrum. 90, 113321 (2019).
- [2] 久保隆宏 著、『Python で学ぶ強化学習 入門から実践まで』、講談社、2019 年。
- [3] 大関真之 著、『ベイズ推定入門』、オーム社、2018 年。
- [4] Yasuyuki Morita *et al.*, “Developments of real time emittance monitors”, Rev. Sci. Instrum. 91, 043303 (2020).
- [5] Tetsuhiko Yorita *et al.*, Proceedings of PASJ in 2021. THP041.
- [6] <https://github.com/SheffieldML/GPyOpt>