

機械学習を用いた SuperKEKB 加速器入射調整ツールの改良

IMPROVEMENT OF MACHINE-LEARNING-ASSISTED INJECTION TUNING FOR SuperKEKB

加藤臣之輔^{#, A)}, 三塚岳^{B)}
Shinnosuke Kato^{#, A)}, Gaku Mitsuka^{B)}
^{A)} The University of Tokyo
^{B)} KEK

Abstract

With the world's highest peak luminosity record, the SuperKEKB accelerator is aiming to break further peak luminosity records. Achieving this goal requires sophisticated and sensitive injection tuning. If we continue to rely on experts to operate as before, more time and effort will be required to make the adjustments. To solve this problem, we have created a machine-learning-assisted injection tuning tool. In this conference, we will report the results of injection tuning tests carried out in SuperKEKB operations in the first half of 2024. We have successfully demonstrated that in limited circumstances, machine learning performs as well as operators in both HER and LER. This research is expected to contribute to the application of machine learning to future collider injection tuning.

1. 導入

2024年7月現在時点で世界最高の瞬間ルミノシティ記録を持つ SuperKEKB 加速器においては、更なる瞬間ルミノシティの記録更新を目指している。目標達成にはビーム衝突点でのビームサイズを絞らなければならず、これにより周回バンチのダイナミックアパーチャが狭くなることで入射調整においてはよりシビアな調整を要求されることとなる。また、現在より高い蓄積電流での運転が必要となるため、ビームの寿命が減少し、より高い入射効率でビームを入射し続けられない限り高電流を維持することができない。このように、高い瞬間ルミノシティの実現を目指そうとすると、より高度で繊細な入射調整が要求される。これまでの SuperKEKB 加速器入射調整では、ビーム運転のオペレーターが知識と経験に基づいて様々なパラメータを調整してきたが、複雑化する調整においてこれまで通りのオペレーターに頼った運転を続けていると、調整までにより多くの時間と労力がかかってしまう。

本研究の目的はこのような入射調整の現状に対して一石を投じるべく、機械学習を導入しオペレーターの調整を補助するツールを作成することである。機械学習による加速器調整は近年注目を集めており、中でもガウス過程回帰[1]を用いたベイズ最適化[2]においては非常に多くの研究が行われている。ベイズ最適化の特長は最適化開始以前の学習データを必要とせず、リアルタイムで取得したデータから学習を進めるため、温度ドリフトをはじめとする様々な環境変化の影響を受けずに最適化を進められる点であり、これは加速器調整と非常に相性が良い。

我々はベイズ最適化の性能を確かめるため、2023年6月と12月に KEK Linac にて陽電子ビーム電荷最大化試験を行った。その結果 11 回の最適化プロセスの全てにおいて、4 分以内にオペレーターの調整値と同程度のビーム電荷まで調整することができた。(紙面の都合上、

試験の詳細は省略する。詳しくは[3]を参照。)そしてこの試験で得られた知見をもとに SuperKEKB 加速器にてベイズ最適化の入射調整試験を行った。衝突型加速器においてベイズ最適化を入射調整に応用した例はなく、この試験は世界初の試みである。入射調整試験では KEK Linac とは違い、ビームロス量が多いと粒子検出器を保護するためにビームアボートが促される。ビームをアボートしてしまうと蓄積リングに溜まった電流を全て失ってしまい、再び電流を蓄積するまでの積分ルミノシティを損ってしまうので本末転倒である。そこで我々はビームロスを考慮した制限付きベイズ最適化を実装した。これによって、ロスモニターの値を監視し、ビームロスが多い部分には負の評価を与えることでロスの多い領域をなるべく探索しないようにすることができる。この試験の結果は、今後高ルミノシティ化するであろう未来の衝突型加速器全てに対して貢献できる知見になると考えている。

なおベイズ最適化の実装に関しては、パラメータ最適化ライブラリである Optuna[4]を用いて BoTorch ベースのコードを動作させており、獲得関数は全て Expected Improvement (EI) 関数を使用した。また、制限付き最適化の詳細と実装方法は[5]を参照すると良い。

2. ビーム輸送路下流から SuperKEKB メインリングへの入射調整

2.1 入射調整の概要

Figure 1 はビーム輸送路 (BT) 下流から SuperKEKB メインリングへの入射調整の概略図である。例として陽電子リング (LER) を図示しているが、電子リング (HER) でもマグネットの配置は同じである。入射調整部では様々なマグネットを用いて入射バンチを蓄積バンチに合流させている。まず 2 台の垂直ステアリングマグネットが入射バンチのビーム鉛直方向の位置を調整する。次にキッカーマグネットが蓄積バンチを蹴り、セプタムマグネットも入射バンチを曲げる。蓄積バンチはセプタムマグネットの中を通るが、このマグネットはチェンバーがセプタム板で区切

s-kato@hep.phys.s.u-tokyo.ac.jp




Figure 3: Schematic view of the initialization for Bayesian optimization.

差を小さくするために入射効率を 10 回測定し、その中央値を用いてベイズ最適化を行なっている。平均値を用いると、外れ値によって平均が大きすぎてしまうため中央値を採用している。上記のように測定した最適化の一点をトライアルと呼ぶことにする。以下では 50 トライアルや 30 トライアルに対して入射効率はどう変化したのかを議論する。

3.2 LER 試験結果

本節では LER において 2024 年 5 月 29 日に行なったベイズ最適化を用いた入射調整の結果を紹介する。LER の蓄積電流を 800 mA まで積み上げ、1 バンチで 5 Hz のトップアップ入射を行なった。試験開始前に入射効率は 96 %と非常に良好であった。我々は敢えて入射効率を 90 %程度まで低下させるような初期値を選択して最適化を開始した。最初の数回の最適化では、各垂直ステアリングマグネットの定義域をそれぞれ、

V-steering 1 : $[-1.60 \times 10^{-4}, -1.45 \times 10^{-4}]$ rad

V-steering 2 : $[-1.45 \times 10^{-4}, -1.05 \times 10^{-4}]$ rad


として実行した。しかし、毎回 (V-steering 1, V-steering 2) = $(-1.56 \times 10^{-4}, -1.31 \times 10^{-4})$ rad 付近でロスモニターの値が極端に高くなり、ビームアボートが発生してしまった。このことから制限つきベイズ最適化は、ロス値が高い領域を測定した際に、その領域周辺を避けるようにするソフトリミットであるため、このように突発的にアボートを引き起こすような変化に対しては対応できないという知見を得た。このようなアボートを(完全ではないにしろ)防ぐためには、ロスモニター値の変化量に閾値を設定し、閾値を超える急激な変化をした際に最適化を止める機能の実装が必要である。その上で、さらにロスモニター値の変化量に対しても制限を付けてベイズ最適化を実行することが求められる。2024 下半期の運転ではこの機能を実装しての最適化を目指す。

次に、ビームアボートをする領域を避けるため定義域を狭めて再び入射調整を開始した。具体的には、V-steering 2 の定義域は変更せず、

V-steering 1 : $[-1.54 \times 10^{-4}, -1.45 \times 10^{-4}]$ rad

と変更した。それでもなおアボートしたので、パラメータ値の変更速度を緩やかにした。その結果ビームアボートを引き起こすことなく 50 トライアルの最適化に成功した。Figure 4 はこの最適化結果を表している。(a)の青線は各トライアルに対しての入射効率を示しており、橙線は Peakhold (各トライアル時点での入射効率の最大値)を表している。また、(b)は各トライアル点を調整パラメータ空間上に描写した図であり、色は入射効率を表す。星マークは入射効率が最大となった点を表している。(a)では 96 %から 86 %まで低下させた入射効率が 98 %まで向上していることが見て取れる。最適化を始めてから 98 %に

到達するまでに経過した時間は 12 分であった。このことから2個マグネットのみを使用し、かつ定義域を狭めた状態でも入射効率向上の余地があることが判明した。また(b)からは、入射効率が高い点が反相関して分布していることが見て取れる。Figure 4 のような最適化プロセスを再度行ったら、同様の結果が得られた。このことからビームアボートを引き起こさないためには、定義域の選定が重要であることがわかる。また、もう一つ特筆すべきこととして、再度パラメータ値を変更する速度を速くしてみるとビームアボートを引き起こした。このことから、定義域が同じでもパラメータ値を変更する速度が速ければビームアボートを起こすことがわかった。



(a) Trial over injection (b) Parameter domain of efficiency and peakhold. 2 vertical steering magnets.

Figure 4: Results of injection tuning using Bayesian optimization at LER.

Figure 5 は Fig. 4 (b) のカラーバーを入射効率からロスモニターの値に差し替えたものである。変更後の定義域ではビームアボートを引き起こすような高いロス値は見られず、全ての点で 10 mRad/s 以下であるので制限を付ける点は存在しなかった。しかし一点のみ他と比べて高い点が存在しており、ロス値が高い領域が連続的ではなく離散的に存在することが見て取れる。




Figure 5: Loss monitor value on parameter domain of 2 vertical steering magnets (LER).

3.3 HER 試験結果

本節では HER において 2024 年 6 月 6 日に行なった、ベイズ最適化を用いた入射調整の結果を紹介する。本試験の直前にはエキスパートによる調整が行われ、800 mA の蓄積電流において 1 バンチ目の入射効率が 37 %、2 バンチ目の入射効率が 45 %の状態から最適化を開始した。

3.3.1 1 バンチ入射での試験結果

まずは 1 バンチ入射での最適化を行なった。HER の蓄積電流を 500 mA まで積み上げ、1 バンチ、5 Hz でトップアップ入射を行なった。パラメータの定義域は以下の通りである。

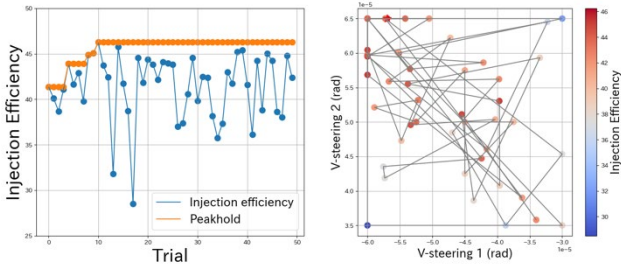
V-steering 1 : $[-5.0 \times 10^{-5}, -3.0 \times 10^{-5}]$ rad

V-steering 2 : $[+3.5 \times 10^{-5}, +6.0 \times 10^{-5}]$ rad

HER では LER と違い、一回もビームアポートを引き起こすことなく 50 トライアルの最適化に成功した。

Figure 6 はこの最適化結果を表している。

(a)では入射効率が 41 %から 46 %まで入射した。(エキスパートが調整した時の入射効率は 37 %であるが、最適化の初めから入射効率がエキスパートを上回っているのは、2 バンチ目の入射効率を考慮していないからである。また 500 mA と 800 mA ではわずかに 800 mA の入射効率が低く見積られることも関係している。) 最適化を始めてから 98 %に到達するまでに経過した時間は 8 分であった。(b)では LER と同じく、入射効率の値が高い点が反相関して分布していた。しかし、定義域の左上の部分に境界に張り付いていることから、定義域の外にも入射効率の高い部分が連続して分布していることが考えられる。また、ロスモニターの値は全ての点において 10 mRad/s 以下であり、制限を付ける点は存在しなかった。



(a) Trial over injection efficiency and peakhold. (b) Parameter domain of 2 vertical steering magnets.

Figure 6: Results of injection tuning using Bayesian optimization at HER (1 bunch injection).

3.3.2 2 バンチ入射での試験結果

次に、電流を 800 mA に上昇させ、2 バンチ、5 Hz でトップアップ入射を行なった。2 バンチでの入射効率の算出は(2)式を用いた。試験時間の関係上、30 トライアルでの最適化を試みた。

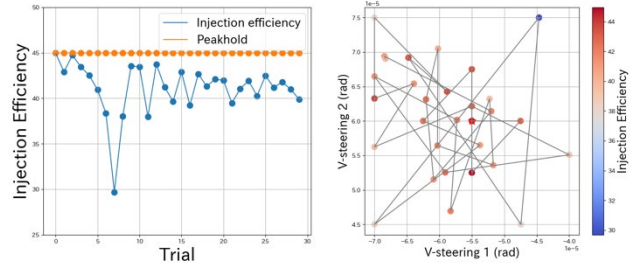
$$Eff_{objective} = \frac{Eff_{1bunch} \times BPM_{1bunch} + Eff_{2bunch} \times BPM_{2bunch}}{BPM_{1bunch} + BPM_{2bunch}} \quad (2)$$

ここで Eff_{ibunch} と BPM_{ibunch} はそれぞれ i バンチ目の入射効率とビーム位置モニタ測定した電流値を表している。 $Eff_{objective}$ を最適化することによって、最もメインリングにビーム電流を蓄積できるような入射効率のペアを得ることができる。また、Fig. 6 において入射効率の値が高い点が境界に張り付いていることを考慮して、定義域を以下のように拡大した。

V-steering 1 : $[-6.0 \times 10^{-5}, -3.0 \times 10^{-5}]$ rad

V-steering 2 : $[+3.5 \times 10^{-5}, +6.5 \times 10^{-5}]$ rad

Figure 7 はこの最適化結果を表している。(a)では入射効率が 45 %であり、試験終了後にこのマグネットのパラメータで入射効率を測定したところ、1 バンチ目の入射効率が 40 %、2 バンチ目の入射効率が 52 %と、実験開始前にエキスパートが調整した値を上回っていた。このことから、HER においても 2 パラメータで十分に入射効率を向上させる余地があることが判明した。また (b)では 1 バンチの時よりも 2 バンチの方がパラメータ間の反相関が弱くなっていることも見て取れる。



(a) Trial over injection efficiency and peakhold. (b) Parameter domain of 2 vertical steering magnets.

Figure 7: Results of injection tuning using Bayesian optimization at HER (2 bunch injection).

参考文献

- [1] C. E. Rasmussen and C. K. I. Williams, "Gaussian Processes for Machine Learning", The MIT Press, 2015, <https://gaussianprocess.org/gpml/>
- [2] R. Garnett, "Bayesian Optimization", Cambridge University Press, 2023, <https://bayesoptbook.com/>
- [3] <https://conference-indico.kek.jp/event/253/timetable/>
- [4] T. Akiba *et al.*, "Optuna: A Next-generation Hyperparameter Optimization Framework", <http://arxiv.org/abs/1907.10902>
- [5] S. Sano *et al.*, "Optuna によるブラックボックス最適化", Ohmsha, 2023, <https://www.ohmsha.co.jp/book/9784274230103/>