

# SuperKEKB 加速器における機械学習を用いたビーム入射調整の高度化 UPGRADE OF BEAM INJECTION TUNING USING MACHINE LEARNING AT THE SuperKEKB ACCELERATOR

加藤臣之輔 <sup>\*,A)</sup>, 三塚岳 <sup>B)</sup>,  
Shinnosuke Kato <sup>\*,A)</sup>, Gaku Mitsuka <sup>B)</sup>,  
<sup>A)</sup> The University of Tokyo  
<sup>B)</sup> Accelerator Laboratory, KEK

## Abstract

As of July 2025, the SuperKEKB accelerator — which collides 7 GeV electrons with 4 GeV positrons to copiously produce particles such as B mesons and  $\tau$  leptons — continues to hold the world record for the highest instantaneous luminosity. To achieve even higher luminosities, the accelerator is undergoing continuous upgrades and operation. Maintaining such high luminosity necessitates sustaining high beam currents in the storage rings, which in turn depends on efficient beam injection from the injector. In particular, maximizing injection efficiency, defined as the ratio of beam current successfully accumulated in the ring to that extracted from the beam transport line, is crucial. In this study, we developed an automated injection tuning tool based on Bayesian optimization, a machine learning-driven approach, aimed at improving injection efficiency. In test runs carried out between November and December 2024, this tool achieved an injection efficiency improvement of up to 32%.

## 1. 導入

SuperKEKB 加速器は電子陽電子加速器であり、2024年12月時点で世界最高の瞬間ルミノシティ記録 ( $5.1 \times 10^{34} \text{ cm}^{-2}\text{s}^{-1}$ ) を保持している。メインリングは周長3 km の蓄積リングであり、7 GeV の電子を蓄積する HER (High Energy Ring) と 4 GeV の陽電子を蓄積する LER (Low Energy Ring) で構成されている。Figure 1 に SuperKEKB 加速器の全体図を記す。

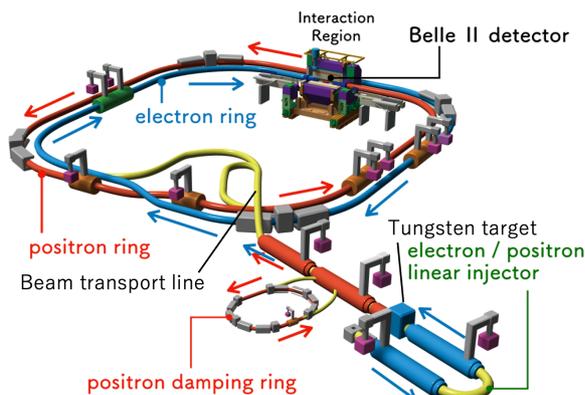


Figure 1: An overview of the SuperKEKB accelerator [1]

メインリングは、直線部とアーク部からなる構造を4つ繰り返して構成されており、メインリング内に入射した粒子は周回を続けながら Belle II 測定器の中で衝突する。

SuperKEKB 加速器において更なる瞬間ルミノシティ記録を達成するためには、入射調整部の高度化が重要な課題となっている。従来の入射調整では、ビーム運転の

オペレーターが自身の知識と経験に基づいて様々なパラメータ調整を行ってきたが、調整プロセスが複雑化する中で従来通りのオペレーター頼りの運転を継続すると、調整にかかる時間と労力が大きく増加することが懸念される。本研究は、このような現状を改善するために機械学習を導入し、オペレーターによる調整を補助する自動入射調整ツールの開発を目的とする。

2025年7月現在、入射部の現実を正確に再現するシミュレーションは存在しておらず、入射調整部は実質的にブラックボックス関数となっている。そのため、実際にデータを測定するまでは、どのパラメータセットが最適な入射効率を達成できるかを事前に予測することが困難である。さらに、最適なパラメータセットは数時間の単位で予測不能な時間変化を示すため、過去に高い効率を示したパラメータセットを再利用しても、改善が見られないことも少なくない。また、入射効率の測定誤差は2-2.5%と比較的大きく、古典的なブラックボックス最適化アルゴリズムである Downhill Simplex 法 [2] が機能しない場合が散見されることが報告されている [3]。加えて、パラメータを大幅に変更するとビームの安定な周回条件を逸脱し、ビームアポートが引き起こされる恐れがある。

以上の手動による入射調整に伴う課題を解決するため、本研究では機械学習を活用した自動入射調整ツールを開発する。本ツールは、衝突型加速器における物理ラン中の入射調整への機械学習導入としては初めての試みであり、極めて挑戦的な取り組みである。本研究で開発する入射調整ツールには、以下の2つの性能を求める。

- **入射効率の向上:** 過去のデータを使用することなく、リアルタイムに入射効率を向上させることができる。また、最適化によって効率が改善されない場合でも、既存の性能を悪化させないことを保証する。
- **安全性の確保:** ビームアポートを引き起こさないように設計され、高い安全性が担保されること。

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

## 2. メインリングへの入射手法

本章ではビーム輸送路下流からメインリングへの入射調整手法について解説する。Figure 2 と Fig. 3 はそれぞれビーム進行方向に対して垂直方向と水平方向の入射部説明図である。

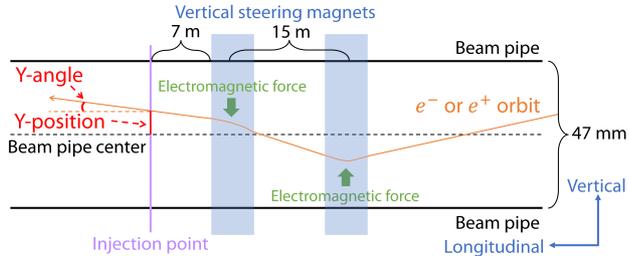


Figure 2: Schematic illustration of the injection system in the vertical plane.

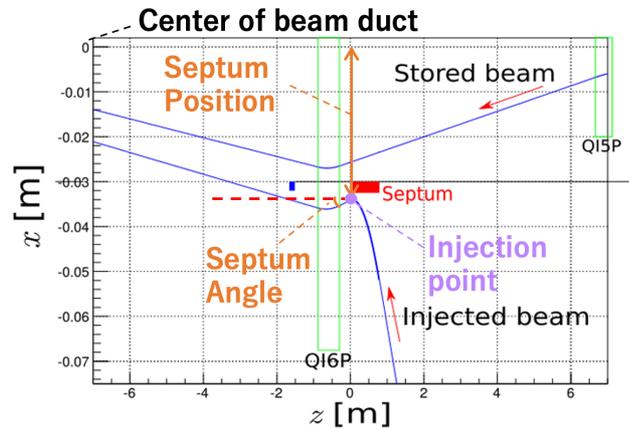


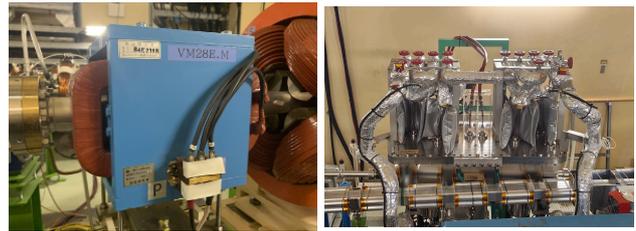
Figure 3: Schematic illustration of the injection system in the horizontal plane [4].

ビーム輸送路から到達する入射バンチに対して、まず垂直ステアリングマグネットを用いて入射点での垂直方向の位置および角度を調整する。その後、セプタムマグネットを用いて、入射点での水平方向のビームダクト中心からの位置と角度を調整する。続いて、四極マグネットにより水平方向のビームダクト中心方向へと軌道を曲げ、最後にキッカーマグネットを用いて蓄積バンチの周回軌道へと軌道を合わせる。Figure 4 に本研究で使用するマグネットの外観を記す。

蓄積バンチに対しては、キッカーマグネットを用いて水平方向の入射バンチに向けて軌道を蹴り、さらに四極マグネットによって水平のビームダクト中心方向に軌道を曲げる。その後、再びキッカーマグネットを用いて蓄積リングの周回軌道に戻すことで入射が完了する。

本研究で用いる入射調整パラメータについて解説する。なお、LER と HER の入射手法は共通であるため、本章では例として LER の入射部を対象に議論を進める。

Figure 2 に示すように、ビーム輸送路下流には 2 つの



(a) Vertical steering magnet (b) Septum magnet

Figure 4: Photograph of the magnets used for injection tuning in this study.

垂直ステアリングマグネット対があり、このマグネットの印加電流を変化させることにより入射ビームの位置と角度を調整できる。垂直ステアリングマグネットの 7 m 後部にある入射地点に到達した時のビームダクト中心からの垂直距離を y-position, 垂直角度を y-angle と定義する。

Figure 3 を見ると、水平方向の調整には主にセプタムマグネットおよびキッカーマグネットが用いられるが、本研究ではセプタムマグネットのみに着目する。入射バンチの軌道を操作するパラメータは Septum Position と Septum Angle の 2 種類であり、それぞれセプタムマグネット端の入射地点におけるビームダクト中心からの水平距離と水平角度に対応する。入射バンチの軌道がビームダクト中心と逆方向に曲げられているのは、入射バンチの水平角度を蓄積バンチの水平角度に近づけるためである。

入射効率 E は Eq. (1) によって与えられる。

$$E = \frac{I_{\text{stored bunch, after injection}} - I_{\text{stored bunch, before injection}}}{I_{\text{injected bunch}}} \quad (1)$$

Equation (1) の分母にあるメインリングへ入射される電流は、ビーム輸送路に設置された stripline BPM (Beam Position Monitor) [5, 6] によって測定される。一方、Eq. (1) の分子はメインリング内に蓄積されたバンチ電流の増加分に対応しており、BCM (Bunch Current Monitor) [6] によって測定されている。

## 3. ベイズ最適化

この節では本研究で用いる機械学習手法であるベイズ最適化 [7, 8] の概要と、入射調整にベイズ最適化を適応させるために必要な機能を紹介する。

ベイズ最適化はブラックボックス最適化の一種である。ブラックボックス最適化とは、数理的構造が明らかになっていない関数の最適化に用いられる手法であり、関数全体の具体形が一切わからないという前提のもとで、観測を通して効率よく最適化を行う手法であり、ガウス過程帰帰法 [9] という確率分布を作成する手法と、獲得関数という確率分布の中でどの点が最も最大値らしいかを表す関数を通じて、少数統計で関数の最大値の確率的予測を効率よく行うことができる最適化手法である。この手法は、リアルタイムで取得された測定データに基づいて関数の予測を行うため、事前に教師データを必要としない点で有用である。

KEK Linac での陽電子収量を最大化する先行研究 [10] では、3つのブラックボックス最適化アルゴリズム（ベイズ最適化、TPE、CMA-ES）の中でベイズ最適化が最も高い性能を示した。以上の理由から、本研究では入射調整に対してベイズ最適化を採用している。

ベイズ最適化を入射調整に適応させるためには、ビームアポートを考慮する必要がある。入射調整パラメータを大きな定義域の中で自由に変更すると、入射由来のビームバックグラウンドが大きくなってしまふ領域が生じ、パラメータがその領域に到達するとビームアポートが発生してしまう。そのため、入射由来のビームバックグラウンドをある一定以下に抑え、安全性を確保した状態でベイズ最適化を実施する必要がある。

以下では、本研究においてベイズ最適化を適応する際に実装した機能を3点紹介する。1点目は小分け最適化であり、ビームロスの大い領域を避けつつ入射効率が良い方向に定義域を伸ばしていく最適化手法である。2点目は step-by-step 機能であり、この機能がなければ、パラメータを動かしている最中にビームアポートを引き起こしてしまう。3点目は近傍探索機能であり、最適化時間を短くするために導入した機能である。

### 3.1 小分け最適化

Figure 5 に示す小分け最適化は、小さなパラメータ定義域を設定し、その中で最適化を繰り返し実施する手法である。経験則として、ビームが安定的に周回している場合にはそのパラメータセットを中心とした十分に小さなパラメータ領域では急激なビームロスが発生しないことが知られている。そのため、調整開始前のパラメータセットを中心に小さな定義域を設定し、その範囲内でベイズ最適化を行う。初期化条件としては、調整前のパラメータセットを基準に定義域の上下10%の範囲内でランダムに点を生成し、それを初期点として使用する。

本研究では、最適化開始前に10点の初期点を生成し、それを基にベイズ最適化を実行する。最適化の1回の評価を「トライアル」と呼び、本研究では1回の最適化において30トライアルを実施する。また、10点の初期点生成と30回の最適化試行を合わせて1回の「ラン」と定義する。1回のランの結果として得られた入射効率の最大値を中心とする狭いパラメータ定義域を新たに設定し、同様の最適化を1~3ラン繰り返す。この手法により、結果的に広い定義域に対しても効率的な探索を行うことが可能となる。一方、この手法には課題が2点存在する。1点目は最適化を複数回繰り返すため、通常のベイズ最適化と比較して時間がかかる傾向にあることである。2点目は、定義域を小さく設定することから、局所的な最大値に捕獲されるリスクが高まり、通常のベイズ最適化と比較して最適化性能が低下する可能性があることである。本研究では調整オペレーターが手動調整する際の経験を元に、1回のランあたりの定義域の幅を定めた。

### 3.2 Step-by-Step 機能

時間あたりのパラメータ変化量が大きすぎる場合、ビーム軌道を補正する軌道フィードバックより早く軌道を変化させてしまうため、ビームアポートを引き起こしてしまう。step-by-step 機能を導入する目的は、入射調整パラメータを時間をかけて少しずつ動かし、振幅の増

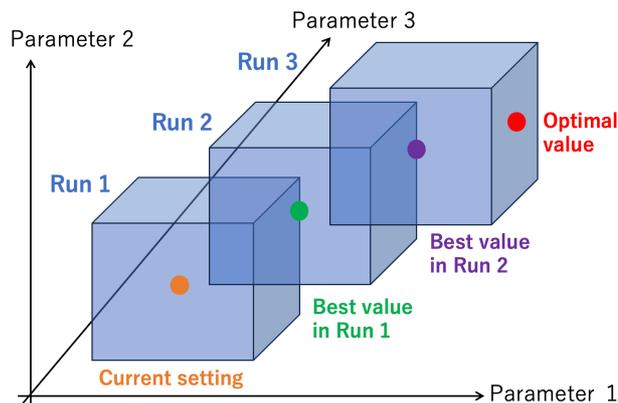


Figure 5: Conceptual illustration of the segmented region optimization. The blue regions represent the parameter domains for each run, which are redefined around the parameter set that achieved the highest injection efficiency in the previous run.

大を緩和することである。Figure 6 に step-by-step 機能の概念図を示した。赤点線は step-by-step 機能を実装しなかった場合の調整パラメータの変動であり、急激な変化が起こっているが、青線の step-by-step 機能を実装しなかった場合の調整パラメータの変動では急激な変化を防ぐことができる。ただし、パラメータを変化させるまでの待機時間が増え、最適化時間も増加するというデメリットが存在する。

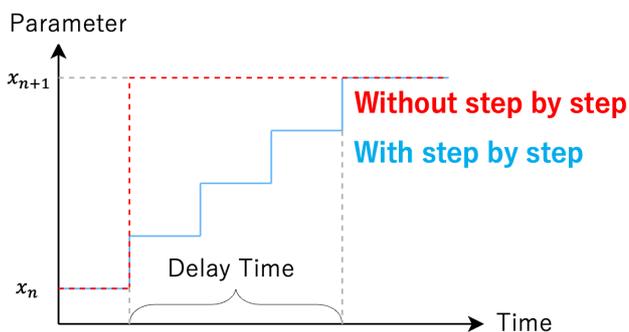


Figure 6: Conceptual illustration of the step-by-step function. The red and blue lines represent the parameter changes before and after the implementation of the step-by-step function, respectively.

### 3.3 近傍探索機能

近傍探索機能とは、獲得関数に対して距離の重み付けをして、現在地点からの距離が近い候補点ほど評価値が高くなるようにする機能である [11, 12]。この機能を導入する理由は、step-by-step 機能を導入してパラメータを大きく動かすと待機時間が増加してしまふため、1トライアルあたりのパラメータ変化量を減少させ、最適化時間を減らすためである。Figure 7 は近傍探索機能の概念図であり、左図ではトライアルごとにパラメータが大き

く変動し、step-by-step 機能による待機時間が多く発生するが、右図ではトライアルあたりの変動が小さいために待機時間を削減することができる。

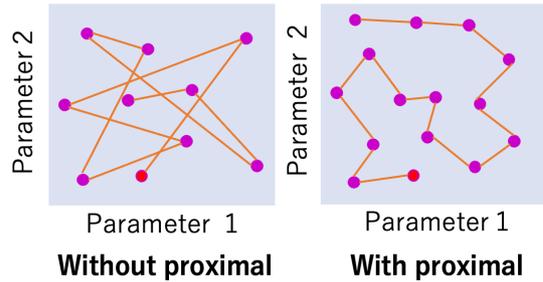


Figure 7: Conceptual illustration of the proximal biasing method. The figure shows the difference in parameter trajectories with and without the proximal biasing method in a two-dimensional parameter space.

Equation (2) は近傍探索の重みづけを表す式である。

$$\tilde{\alpha}(\mathbf{x}^*) = \alpha(\mathbf{x}^*) \exp\left(-\frac{w^2(\mathbf{x}^* - \mathbf{x}_0)^2}{2}\right) \quad (2)$$

$\tilde{\alpha}(\mathbf{x})$  は重みづけ後の獲得関数、 $\alpha(\mathbf{x})$  が重みづけ前の獲得関数、 $\mathbf{x}_0$  が現時点でのパラメータセットである。探索点  $\mathbf{x}^*$  と  $\mathbf{x}_0$  の距離が離れているほど  $\tilde{\alpha}(\mathbf{x})$  が小さく見積もられる。 $w$  は重み付けのハイパーパラメータであり、近傍探索度と呼ぶ。近傍探索度が大きいほど現在のパラメータと距離が近いパラメータが優先されるようになる。近傍探索機能のデメリットは、最適化性能が低下することである。Equation (2) を用いると、距離による重み付けによって現在位置と距離が近いパラメータが優先されるため、獲得関数が定めた最も最大値らしい値を反映しない。近傍探索度は最適化性能と最適化時間のトレードオフな関係を調整する役割を持つ。

## 4. 測定結果

本章では、ベイズ最適化の評価パラメータである入射効率の測定誤差およびふらつきについて議論し、その後小分けベイズ最適化を用いた入射調整ツールの長期運用結果を述べる。なお、本研究はメインリングへの入射調整に機械学習を初めて適用する試みであるため、最初の適用対象として、重要性が高く、かつ機器の損傷リスクが比較的低い y-position、y-angle および Septum Angle の3つを調整パラメータとして選定した。

### 4.1 入射効率の誤差

ベイズ最適化の評価パラメータである入射効率の測定誤差およびふらつきについて論じる。本研究では、入射効率を使用する際、測定誤差を低減する目的で30回の測定値の中央値を採用している。平均値ではなく中央値を採用した理由は、稀に入射効率が極端に低い外れ値となる場合があり、それが平均値に大きく影響を与えるためである。Figure 8に、KEK Linacからメインリングまでビーム状態を変更せずに加速器運転を行った30分間

の入射効率の変動と、30回の移動中央値を適用した結果を示す。青線が入射効率、橙線が入射効率の30点の移動中央値を表しており、入射効率の中央値自体がふらついていることが見て取れる。30分間における入射効率の測定結果から、平均値は67%、標準偏差は2.7%であることがわかった。

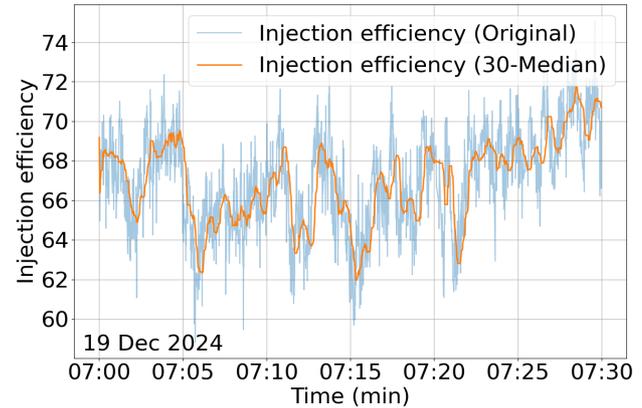


Figure 8: Injection efficiency measured over a 30-minute period during which the beam conditions were kept constant. The blue line indicates the injection efficiency, and the orange line represents the 30-point moving median of the injection efficiency.

Figure 8に示されている入射効率は、特定のビーム条件下での30分間のデータに基づくものである点に留意が必要である。同様の解析を別の日の異なるビーム条件において計3回実施した結果、入射効率のばらつきは蓄積電流や入射効率に依存せず、時期や条件により異なる値を示した。本研究では入射効率のばらつきを3日の標準偏差の平均値として設定し、HERでは2.5%、LERでは2.3%と定義した。また、ベイズ最適化による調整を行った結果、最適化前後で入射効率が標準偏差の3倍以上向上した場合に、統計的に有意な改善があったと判断する。本研究では、具体的な判定基準として、HERにおいては7.5%、LERにおいては7.0%以上の入射効率の向上を採用した。

### 4.2 長期運用テスト

2024年11月14日から12月25日の期間において、HERでは4日間、LERでは8日間の入射調整ツールのテスト運用を実施した。その結果を日ごとに整理した入射効率の向上量をFigure 9に示す。(a)、(b)はHERおよびLERにおける入射効率の向上量、(c)、(d)は同様に調整前後の入射効率の変化を示している。

本ツールの最適化性能について議論する。第3章において、ベイズ最適化による入射効率の向上が統計的に有意である条件を、HERでは7.5%、LERでは7.0%以上の向上と定義した。Figure 9に示された結果から、HERでは4回中2回、LERでは8回中4回の最適化が統計的に有意であることが確認された。また、近傍探索度を導入することで、最適化時間が2~5分短縮されることが確認された。

本ツールのビームアポートに対する安全性について議

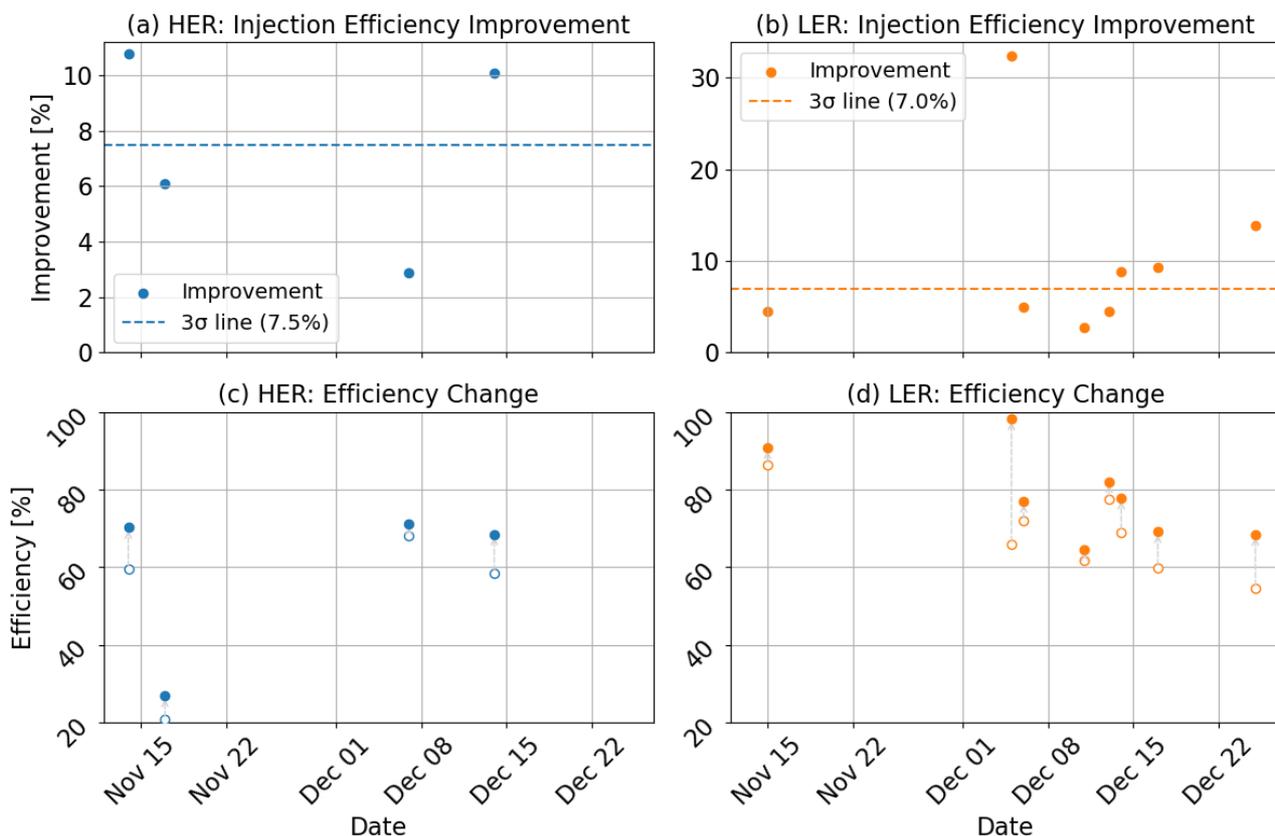


Figure 9: Optimization results from the test deployment between November 14 and December 25, 2024.

論する。入射由来のビームバックグラウンドによりビームがアポートされる場合、Belle II 測定器付近に設置されたシンチレータ式またはダイヤモンドセンサー式のロスモニターがアポートトリガーを発する。今回実施した全てのランにおいて、これら 2 種類のロスモニターがアポートトリガーを出した事例は一度も確認されなかった。この結果は、小分け最適化および step-by-step 機能の導入により、本ツールがビームアポートに対して高い安全性を有していることを示している。

## 5. 結論と展望

SuperKEKB 加速器では更なる高ルミノシティ化のために入射調整部を高度化する必要がある、本研究では機械学習手法の一種であるベイズ最適化を用いて入射調整ツールを開発した。

本研究では入射調整にベイズ最適化を適応させるために必要な機能を 3 点導入した。1 点目はビームロスの大きいパラメータ空間での最適化避けるために、小さなパラメータ定義域で最適化を行い、入射効率が良い方向に定義域を伸ばしていく手法である小分け最適化である。2 点目はビームアポートを防ぐための step-by-step 機能であり、3 点目は最適化時間を短くするために導入した近傍探索機能である。小分け最適化と step-by-step 機能を導入することで、11 月と 12 月に実施したすべての最適化において入射起因のアポートが発生しなかった。ま

た、近傍探索度を導入することで、最適化時間を 2-5 分短縮することに成功した。

本ツールを HER で 4 日間、LER で 8 日間運用した結果、HER では 2 日間、LER では 4 日間において入射効率が測定の前を上回る統計的に有意な向上を示した。

展望として、以下の二点の改良を計画している。一点目は調整パラメータの数を増やすことである。具体的には、入射位相の情報や、ビーム輸送路上、中流に設置された水平・垂直ステアリングマグネットの導入を検討している。二点目は目的関数があらかじめ定めた閾値を下回らないようにする制約付き最適化の導入である [13]。この機能が実現できれば、最適化の過程においても入射効率が著しく低下する事態を防止することができる。

## 参考文献

- [1] SuperKEKB Collaboration. Superkekb design report, overview, 2019. Available at: [https://www-linac.kek.jp/linac-com/report/skb-tdr/2\\_MachineParameters.pdf](https://www-linac.kek.jp/linac-com/report/skb-tdr/2_MachineParameters.pdf)
- [2] J. A. Nelder and R. Mead. A simplex method for function minimization. *The Computer Journal*, 7(4):308-313, 01 1965.
- [3] Takuya Natsui. SuperKEKB positron beam tuning using machine learning. In *EPJ Web of Conferences*, volume 315, page 02004, 2024. International Workshop on Future Linear

- Colliders (LCWS2024), Tokyo, Japan, July 8–11, 2024.
- [4] SuperKEKB Collaboration. Superkekb design report, beam transport, 2020. Available at: [https://www-linac.kek.jp/linac-com/report/skb-tdr/10\\_BT\\_Revised2020\\_10\\_20.pdf](https://www-linac.kek.jp/linac-com/report/skb-tdr/10_BT_Revised2020_10_20.pdf)
- [5] Tsuyoshi Suwada, N Kamikubota, H Fukuma, N Akasaka, and H Kobayashi. Stripline-type beam-position-monitor system for single-bunch electron/positron beams. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 440:307–319, 02 2000.
- [6] SuperKEKB Collaboration. Superkekb design report, beam instrumentation, 2020. Available at: [https://kds.kek.jp/event/15914/contributions/28491/attachments/136900/166652/BeamInstrumentation2020\\_10\\_19s.pdf](https://kds.kek.jp/event/15914/contributions/28491/attachments/136900/166652/BeamInstrumentation2020_10_19s.pdf)
- [7] J. Mockus, V. Tiesis, and A. Zilinskas. The application of bayesian methods for seeking the extremum. In L. C. W. Dixon and G. P. Szego, editors, *Towards Global Optimization*, volume 2, pages 117–129. Elsevier, 1978.
- [8] J. Mockus. *Bayesian Approach to Global Optimization: Theory and Applications*. Kluwer Academic Publishers, Dordrecht, Netherlands, 1989.
- [9] Carl Edward Rasmussen and Christopher K. I. Williams. *Gaussian Processes for Machine Learning*. MIT Press, Cambridge, MA, 2006.
- [10] Gaku Mitsuka, Shinnosuke Kato, Naoko Iida, Takuya Natsui, and Masanori Satoh. Machine-learning approach for operating electron beam at kek electron/positron injector linac. *Phys. Rev. Accel. Beams*, 27:084601, Aug 2024.
- [11] Auralee Edelen Ryan Roussel. Proximal biasing for bayesian optimization and characterization of physical systems, 2021. NeurIPS Workshop on Machine Learning and the Physical Sciences.
- [12] Ryan Roussel et al. Bayesian optimization algorithms for accelerator physics. *Phys. Rev. Accel. Beams*, 27(8):084801, 2024.
- [13] G. Mitsuka. Application of constrained bayesian optimization to tuning particle accelerators. In *Proceedings of the 22nd Annual Meeting of the Particle Accelerator Society of Japan*, Tokyo, Japan, August 2025.