

機械学習を適用した KEK 電子陽電子入射器ビーム調整システムの開発

R&D OF THE KEK ELECTRON/POSITRON INJECTOR LINAC TUNING BASED ON MACHINE LEARNING

久野彰浩^{#, A)}, 岩崎昌子^{A) B) C) D)}, 佐藤政則^{E) F)}, 佐武いつか^{E)},
中島悠太^{D)}, 武村紀子^{D)}, 長原一^{D)}, 中野貴志^{C) D)}

Akihiro Hisano^{#, A)}, Masako Iwasaki^{A) B) C) D)}, Masanori Satoh^{E) F)}, Itsuka Satake^{E)},
Yuta Nakashima^{D)}, Noriko Takemura^{D)}, Hajime Nagahara^{D)}, Takashi Nakano^{C) D)}

^{A)} Osaka City University Graduate School of Science,

^{B)} Nambu Yoichiro Institute of Theoretical and Experimental Physics (NITEP),

^{C)} Research Center for Nuclear Physics, Osaka University (RCNP)

^{D)} Osaka University Institute for Datability Science (IDS)

^{E)} High Energy Accelerator Research Organization (KEK)

^{F)} The Graduate University for Advanced Studies (SOKENDAI), Department of Accelerator Science

Abstract

We have developed a machine-learning-based operation tuning scheme for the KEK e-/e+ injector linac (Linac), to improve the injection efficiency. The tuning scheme is based on the various accelerator operation data (control parameters, monitoring data and environmental data) of Linac. In this paper, we show the current status and the new results on the research and development of the operation tuning scheme using the Deep Neural Network (DNN), using the Linac operation data accumulated in 2018 to 2021.

1. はじめに

本研究では、高エネルギー加速器研究機構(KEK)で稼働中の、電子・陽電子入射器 Linac の入射効率向上させることを目的として、機械学習を用いた加速器運転調整手法の開発を行った。Linac 運転調整においては、以下の課題がある。

- 調整に関わるマシンパラメータの数が多く($O(1000)$)、パラメータ間の相関が複雑である。また、高度かつ複雑な調整が必要となるため、オペレーターの技量や経験によって調整性能や速度が異なる。
- 振動や温度変化等、加速器周囲の環境変化により、同じマシンパラメータ設定でも同じ入射性能が得られるとは限らない。高い入射効率を得るために、常に環境変化に適合した設定値最適化が必要である。

我々はこれまでに、加速器調整時間の高速化や調整性能の向上、安定化を行うために、機械学習を導入した加速器運転調整手法として、1) ニューラルネットワーク(Deep Neural Network, DNN)を用いた加速器の状態を可視化する手法の開発[1]、および、2) 加速器環境データを入力すると最適な運転パラメータ値を出力する DNN のデザインと、その性能評価[2]を行った。

1)については、VAE(Variational Auto-Encoder [3]、教師無し学習)と呼ばれる手法を用いて、加速器の状態の可視化を行った。また、2018年11月から2020年5月までの間に蓄積した Linac 加速器運転データを可視化することで、加速器の状態は短期的には連続的に変化しているが、長期的には不連続かつ大きな変化が生じていることが分かった。[1]

2)については、蓄積データの中で入射効率の高いデータを用いて DNN を学習させて、運転パラメータについて入射効率を高める事のできるような調整最適値を予測することが出来た。一方で、学習に利用していない期間のデータについてはパラメータの最適値予測を行う事が出来なかった。これは、加速器の状態が変化し、異なる相関関係(モデル)となってしまった事を示唆している。そこで、加速器の状態変化に適応するために、DNN の学習を直近データ(約 1 日分)によって更新しつつパラメータの最適値予測を行う手法を導入した。その結果、適切にパラメータの最適値予測を行うことが出来た[2]。

以上の結果より、加速器の運転パラメータと入射効率のモデルは時間の経過とともに変化していることと、直前データを用いることで DNN はモデルを学習可能であることが明らかになった。

本研究では、先行研究に利用したデータに加えて、




Figure 1: Accelerator placement at KEK.

[#] m20sa029@uv.osaka-cu.ac.jp

2021年6月までに蓄積されたデータを追加し、さらに高統計なデータで開発を行った。

先行研究の結果である、加速器の各種パラメータと入射効率のモデルが学習可能である事を利用して、より入射効率を向上させる事の出来るパラメータ調整機構の開発を行いたい。そのためには、以下の事項についての開発が必要である。

1. 加速器の各種パラメータを入力として入射効率を予測する DNN の開発
2. 開発した DNN を用いたパラメータ最適化機構の開発

よって、本研究では、上記開発事項の中で前段目標である 1. の基礎研究として、加速器の各種パラメータを入力すれば入射効率の予測値を出力する DNN をデザインし、Linac 加速器の実データを用いて入射効率の予測精度の検証を行った。本稿ではこれらの検証結果について報告する。

2. Linac 加速器

Figure 1 に、Linac 加速器及び、Linac 加速器から入射される種々の加速器の配置図を示す。Linac 加速器は長さ 600m の線形加速器で、最大 50Hz、2 バンチ(96ns 間隔)運転が可能であり、電子・陽電子を 4 つのリング型加速器、Photon Factory(PF)、PF Advanced Ring(PF-AR)、SuperKEKB 電子リング(HER)、陽電子リング(LER)へ振り分け供給している。

また Fig. 2 に Linac 加速器の全体図を示す。Linac 加速器にはビーム位置モニター(BPM)が 100 台、ステアリング電磁石が 30 台、RF モニターが 60 台配置されている。

3. 加速器入射効率を予測する DNN の開発

3.1 加速器パラメータについて

本研究では 2018 年 11 月から 2021 年 6 月の期間に蓄積された、Super KEKB 電子ビーム(HER)用の Linac 加速器運転データを使用した。

DNN の入力データとして、以下の計 1232 パラメータを使用した。

- 電磁石パラメータ(電磁石励磁電流値読み返し値):500 個
 - 環境パラメータ(環境温度、冷却水温など):732 個
- これは後述するデータセット全てに共通である。

また、DNN の出力である Linac 加速器の入射効率の定量的指標として、加速器上流と下流の BPM における電荷量の比 Q_{ratio} を利用した。

$$Q_{ratio} = \frac{(5\text{ Sector 最後の電荷量})}{(A\text{ Sector 最初の電荷量})}$$

Figure 3 に、今回使用したデータにおける入射効率分布を示す。Fig. 3 に示される通り、データは入射効率の高効率側に偏った分布になっている。DNN を学習する際には、入射効率に対して、均一な分布となった学習用データが必要である。したがって、Fig. 3 の赤線で示されるように、入射効率に対して、均一な分布となるようデータ抽出を行って、学習用データを作成した。

データ数




Figure 3: Injection efficiency (Q -ratio) for the Linac HER beam (electron beam).

3.2 開発に使用したデータセットについて

DNN による入射効率予測の検証を行うために、2018 年 11 月から 2021 年 6 月までに蓄積された加速器運転データから 150,000 event を抽出してデータセットを作成した。ここで、先述の通り、データセットに含まれる入射効率を均一にするため、以下 3 つの入射効率領域において各 50,000 event ずつデータを抽出し、合計 150,000 event のデータセットとした。

- 入射効率 0.85 以上 0.90 未満
- 入射効率 0.90 以上 0.95 未満
- 入射効率 0.95 以上

150,000 event のうち 135,000 event を学習用データ、15,000 event を検証用データとした。Fig. 4 にデータセットの概略を示す。




Figure 2: Layout of Linac.

学習用データ	2018/11/12	135000 event	2021/06/23
検証用データ	2018/11/12	15000 event	2021/06/23

Figure 4: Outline of dataset (2018/11-2021/06).

また、先行研究から、加速器の各種パラメータと入射効率の相関が時間とともに変化している事が分かっている[1]。学習用データの取得時刻・期間と検証用データに対する詳細な検証を行うために、以下の3つの取得期間について、それぞれ 135,000 event の学習用データを抽出した。

- データ (i) 2018 年 11 月から 2021 年 5 月
- データ (ii) 2018 年 11 月から 2021 年 4 月
- データ (iii) 2021 年 5 月

これらの学習用データも、データセットに含まれる入射効率を均一にするため、Fig. 4 のデータセットを作成した際に同様の抽出を行った。

データセット(i)-(iii)での検証用データは、学習用データとは異なる期間に取得されたデータを使用し、2021 年 6 月に蓄積されたデータから 20,000 event を抽出した。Fig. 5 に、データセット(i)-(iii)の概略を示す。

学習用データ	検証用データ
2018/11/12	2021/05/26 2021/06/16 2021/06/23
データ(i)	135000 event 20000 event
データ(ii)	135000 event 使用しない 20000 event
データ(iii)	使用しない 135000 event 20000 event

2021/04/28

Figure 5: Outline of dataset (Collected by period).

3.3 入射効率予測用 DNN について

本研究では、加速器パラメータ 1232 パラメータを入力し、入射効率の定量的指標 Q_{ratio} を出力する DNN をデザインした。DNN の実装は、Tensorflow[4]を用いた。

以下、本研究で構築した DNN の構成を示す。

- Epoch 数 : 50
- Batch size : 2048
- Optimizer : Adam
- Loss 関数 : mean squared error
- 中間層の数 : 4 層
- Drop out 層 : 1 層

3.4 DNN による入射効率予測の検証

Figure 4 で示したデータセット(2018 年 11 月から 2021 年 6 月)を用いて DNN の学習、および、DNN が予測した入射効率に対する検証を行った。Fig. 6 に、DNN が予測した入射効率(橙色)と実際の入射効率(青色)との比較を示す(2020 年 11 月 30 日から 2020 年 12 月 7 日までの区間にについて表示)。ここで、Fig. 6 の縦軸は入射効率、横軸は日時を示す。また、データ全区間(2018 年 11 月から 2021 年 6 月)に対して、DNN が予測した入射効率と実際の入射効率の平均二乗誤差 (MSE) は 0.00030 となった。




Figure 6: Injection efficiencies (Q-ratios) of predicted by DNN (orange) and actual (blue), for 2020/11/30-2020/12/07 evaluation data. Vertical and horizontal axis indicate injection efficiency and date, respectively.

これらの結果から、DNN が加速器パラメータと入射効率の相関関係(モデル)を学習し、入射効率を適切に予測可能であることが示された。

3.5 過去データで学習した DNN による入射効率予測の検証

実際に DNN を用いた加速器運転調整を行うためには、あらかじめ学習した DNN(過去データで学習した DNN)を用いて、入射効率を予測し、調整を行う。そこで、Fig. 5 に示したデータセット(i)-(iii)を使用して、学習用データの取得時刻・期間と検証用データに対する検証を行った。

データセット(i)による検証

2021 年 5 月までのデータで DNN を学習し、2021 年 6 月のデータで検証を行った(データセット(i))。Fig. 7 に、DNN が予測した入射効率(橙色)と実際の入射効率(青色)との比較を示す。DNN が予測した入射効率と実際の入射効率の平均二乗誤差 (MSE) は 0.00038 となり、3.3 節で示された値、0.00030 と非常に近い値になっている。

したがって、2018 年 11 月から 2021 年 5 月までのデータで学習した DNN を用いて、学習に利用していない 2021 年 6 月の入射効率が予測出来ていると考えられる。




Figure 7: Injection efficiencies (Q-ratios) of predicted by DNN (orange) and actual (blue), for 2021 June evaluation data. DNN is trained using 2018 Nov-2021 May data. Vertical and horizontal axis indicate injection efficiency and date, respectively.

データセット(i)-(iii)を用いた検証

学習用データの取得時刻・期間と検証用データの関係を調べるために、Fig. 5 に示したデータセット(i)-(iii)を作成し、検証を行った。ここで、データセット(ii)の学習用データの取得期間は 2018 年 11 月から 2021 年 4 月まで、データセット(iii)の学習用データ取得期間は 2021 年 5 月である。前節と同様に、2021 年 6 月のデータで検証を行った

Figure 8 に、DNN が予測した入射効率(学習用データ(i)青色、(ii)燈色、(iii)緑色)と実際の入射効率(赤色)との比較を示す。また、DNN が予測した入射効率と実際の入射効率の平均二乗誤差 (MSE) は、0.00038(i), 0.00300(ii), 0.00038(iii)となり、データセット(ii)の場合、MSE の値が大きくなっている。

したがって、2021 年 5 月を含む、学習用データ(i)と(iii)では、2021 年 6 月の入射効率を予測可能であるが、2021 年 4 月までの学習用データ(ii)では、予測精度が大きく劣化することが明らかになった。




Figure 8: Predicted injection efficiencies (Q-ratios) by DNN with dataset (i) (blue), (ii) (orange), and (iii) (green), and actual injection eff. (red), for 2021 June evaluation data. Vertical and horizontal axis indicate injection efficiency and date, respectively.

VAE を用いた検証

前節の結果から、検証用データ(2021 年 6 月)の入射効率を予測するためには、2021 年 5 月の学習用データ

が必要であることが明らかになった。2021 年 6 月のデータと 2021 年 5 月のデータについて、さらに検証を行うため、先行研究で開発した、VAE(変分オートエンコーダ)を用いた加速器データの可視化手法[1]を利用した。

2018 年 11 月から 2021 年 5 月までの加速器データを用いて VAE の学習を行い、学習済み VAE に未知期間である 2021 年 6 月の加速器データを入力した。可視化結果を Fig. 9 に示す。なお、Fig. 9 の可視化結果は入力した加速器データに対応する入射効率の値によって着色している。




Figure 9: VAE output (two-dimensional Latent variables) from the 2018 Nov to 2021 June accelerator data. VAE is trained using 2018 Nov to 2021 May data. The output results are colored according to the injection efficiency (Q-ratio) of the input accelerator data.

Figure 9 のプロットから、2021 年 6 月のデータから得られた VAE の出力は、2021 年 5 月のデータから得られた VAE の出力と最も近接して分布している、という結果が得られた。これは、2021 年 5 月の加速器データが 2021 年 6 月の加速器データと類似したモデル(加速器パラメータ間の相関関係)である事を示している。

したがって、過去データで学習した DNN で入射効率を予測するためには、学習用データのモデルが、現行の加速器パラメータモデルと類似していること、あるいは、予測を行いたい期間のモデルを学習用データがカバーしている必要があることが、明らかになった。

ここで、先行研究では、加速器の状態は、長期的には不連続かつ大きな変化が生じているが、短期的には連続的に変化しているが分かっている[1]。

したがって、先行研究、および、今回の結果から、予測を行いたい期間に近い期間の加速器データを使用した DNN の学習が重要であると考えられる。加速器調整のためのテストラン等を定期的に設けることが、有効であると考えられる。

3.6 学習用データの統計量の検証

本研究では、学習用データの統計量と入射効率予測精度の検証を行った。この検証では、Fig. 5 に示したデータセット(i)について、135,000 event の学習用データを各 27,000 event、5 つのデータセットに分割した。概略を Fig. 10 に示す。



Figure 10: Outline of dataset split.

分割前(135,000 event)と分割後(27,000 event × 5)のデータでそれぞれ DNN の学習を行い、検証を行った。DNN が予測した入射効率のプロットを Fig. 11 に示す。分割前データで学習した DNN が予測した入射効率を青色で、分割後データで学習した DNN が予測した入射効率を灰色で、それぞれ示している。

また、DNN が予測した入射効率と実際の入射効率の平均二乗誤差(MSE)は、分割前データで学習した DNN では 0.00036, 5 つに分割されたデータで学習した DNN ではそれぞれ 0.00044, 0.00036, 0.00046, 0.00068, 0.00039 となった。

これらの結果、学習用データの統計量を上げることで、入射効率予測精度が上がる事が示された




Figure 11: Predicted injection efficiencies (Q-ratios) by DNN with the whole dataset (i) (blue) and divided data sets (gray), for 2021 June evaluation data. Vertical and horizontal axis indicate the injection efficiency and date, respectively.

4. まとめ

機械学習を適用した高エネルギー加速器研究機構(KEK)における電子陽電子入射器(Linac 加速器)運転調整システムの開発を行った。

2018 年 11 月から 2021 年 6 月までに蓄積された Linac 加速器の実データを用いて検証を行った結果、加速器パラメータから入射効率を予測することが可能であることを示した。したがって、DNN によって、加速器パラメータと入射効率の相関関係(モデル)を学習し、適切に記述することで、加速器の各種パラメータから入射効率予測が可能である事を示した。

また、2018 年 11 月から 2021 年 5 月までに蓄積されたデータを学習用データ、2021 年 6 月のデータを検証用データとして、DNN の学習と検証を行った。その結果、学習用データのモデルが、予測したい期間の加速器パラメータモデルと類似していること、あるいは、予測を行いたい期間のモデルを学習用データがカバーしている

必要があることが、明らかになった。

また学習用データの統計量を増やすことで、入射効率の予測精度が向上することを示した。今後は、学習用データの統計量を確保する手段として、加速器シミュレーターの開発を検討したい。

また、本研究で開発した、加速器パラメータから入射効率を予測する DNN を用いて、実際にパラメータ最適化を行う手法についても継続して開発を進めたいと考えている。具体的には、DNN への入力パラメータ値を変化させることで、入射効率を向上させるパラメータ値の最適化手法を検討している。Fig. 12 は、特定の加速器パラメータ値を変化させた時の、DNN からの出力入射効率を示す。加速器パラメータの値を、実際の設定値から変化させると、予想される入射効率の値が変化していることが示されている。今後、より具体的な手法を検討、開発ていきたい。




Figure 12: Predicted injection efficiency (Q-ratio) by DNN (vertical) vs accelerator parameter value (Steering magnet current for sector 3) (horizontal). The predicted injection efficiencies are obtained by DNN by varying the input Steering magnet current for sector 3.

謝辞

本研究は、大阪大学核物理研究センター(RCNP)研究プロジェクト、大阪大学データビリティフロンティア機構学際プロジェクトから、多大なご協力を頂きました。また、本研究の一部は、文部科学省「ダイバーシティ研究環境実現イニシアティブ(牽引型)」連携型共同研究助成を受けて、実施されました。

参考文献

- [1] A. Hisano, M. Iwasaki, M. Satoh *et al.*, “強化学習を用いた KEK Linac 加速器運転調整のための準備研究”, Proc. 17th Annu. Meet. Part. Accel. Soc. Japan, pp. 743–746, 2020.
- [2] 久野彰浩, 岩崎昌子, 佐藤政則, 他 5 名, “強化学習を用いた KEK Linac 加速器運転調整システムの開発” 日本物理学会第 76 回年次大会 2021 年 3 月.
- [3] D. P. Kingma, and M. Welling, “Auto-Encoding Variational Bayes”, arXiv:1312.6114, 2014.
- [4] TensorFlow; <https://www.tensorflow.org/>