

## 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

### R&D OF THE KEK LINAC ACCELERATOR TUNING BASED ON REINFORCEMENT STUDY

久野彰浩<sup>#, A)</sup>, 岩崎昌子<sup>A) B) C) D)</sup>, 佐藤政則<sup>E)</sup>, 佐武いつか<sup>E)</sup>,  
中島悠太<sup>D)</sup>, 武村紀子<sup>D)</sup>, 長原一<sup>D)</sup>, 中野貴志<sup>C) D)</sup>  
Akihiro Hisano<sup>#, A)</sup>, Masako Iwasaki<sup>A) B) C) D)</sup>, Masanori Sato<sup>E)</sup>, Itsuka Satake<sup>E)</sup>,  
Yuta Nakashima<sup>D)</sup>, Noriko Takemura<sup>D)</sup>, Hajime Nagahara<sup>D)</sup>, Takashi Nakano<sup>C) D)</sup>  
<sup>A)</sup> Osaka City University Graduate School of Science,  
<sup>B)</sup> Nambu Yoichiro Institute of Theoretical and Experimental Physics (NITEP),  
<sup>C)</sup> Research Center for Nuclear Physics, Osaka University (RCNP)  
<sup>D)</sup> Osaka University Institute for Data Science (IDS)  
<sup>E)</sup> High Energy Accelerator Research Organization (KEK)

#### 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. For the studies, we use the accumulated Linac operation data. In this paper, we show 1) the study of the long-term correlation between the accelerator operation parameters and the environmental data, and 2) the preparation study of the environment-driven machine learning (reinforcement learning) based on the short-term correlation between the accelerator operation parameters and the environmental data to improve the injection efficiency.

#### 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 の入射効率を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、以下の問題がある。

- 加速器周囲の環境の変化等により、同じマシンパラメータ設定で加速器を動作させても、同じ入射性能が得られるとは限らない。したがって、高い入射効率を得るために、常に設定値の最適化が必要である。
- 調整に関わるマシンパラメータの数が多く、その中から相関を見つけることが困難である。また、マシンパラメータ調整において、最適化を行う速さ、調整性能が、オペレータによって異なることがある。

したがって、我々は、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の開発を行った[1]。具体的には、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ニューラルネットワークをデザインした。

このニューラルネットワークについて、2018年11月から2019年11月までの期間に取得された Linac 加速器運転データで検証を行ったところ、加速器環境データから、運転パラメータ値を予測することが可能であることが示された。一方で、ニューラルネットワークの学習に用いたデータと異なる時期については、運転パラメータ調整値の予測ができなかった。この結果は、加速器環境データと運転パラメータの相関関係が、long-term(1週間~数

か月程度)な時間の経過に従って変化している可能性を示唆している。環境データと運転パラメータの相関関係が、時間の経過に従って変化している場合は、刻々と変化する周囲の環境に応じて学習を行う、環境駆動型機械学習(強化学習)が、加速器運転パラメータ制御に有効であると考えられる(short-termでの学習)。

したがって、本研究では、1) 運転パラメータと環境パラメータの相関関係の時間変化についての検証、および、2) 強化学習を導入した運転調整システム開発の準備研究を行った。1)については、加速器環境データ分布傾向の、ニューラルネットワークによる可視化を行った。また、2)については、直近の加速器環境データを入力すれば、入射効率予測値を出力するニューラルネットワークをデザインし、時系列に沿って学習と予測を繰り返すこ




Figure 1: Accelerator placement at KEK.

<sup>#</sup> m20sa029@uv.osaka-cu.ac.jp




Figure 2: Layout of Linac.

とで、加速器環境データの変化傾向に適応しつつ入射効率の予測ができるか性能評価を行った。

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

図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[2]。

本研究では、SuperKEKB 加速器 HER リングへの入射データを用いて開発を行った。

また図2に Linac 加速器の全体図を示す。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。

### 2.1 注目する加速器パラメータ

本研究では 2018 年 11 月から 2019 年 12 月の期間と 2020 年 3 月から 2020 年 5 月の期間に蓄積された、SuperKEKB HER 用の Linac 加速器運転データを使用した。

収集データから、加速器環境データとして以下のパラメータに注目する。

- 電磁石パラメータ(電磁石励磁電流値読み返し値):320 個
  - 環境パラメータ(環境温度、冷却水温など):495 個
- また、この環境データに対応する運転パラメータとして、3 sector 2 個目のステアリング電磁石の垂直方向パラメータに注目する。加えて、Linac 加速器の入射効率の指標として、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。

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

## 3. 実装したニューラルネットワーク

本研究では、加速器環境データを可視化するためのニューラルネットワーク、および、環境データから入射効率を予測するニューラルネットワークを実装した。

なお、ニューラルネットワークの実装は、Tensorflow[3] および Keras[4]を用いて行った。

### 3.1 加速器環境データの可視化手法

本研究では加速器環境データを可視化するために、ニューラルネットワークの一種である変分オートエンコーダー(Auto-Encoding Variational Bayes, VAE[5])を利用した。変分オートエンコーダーとは、入力データを任意次元の「潜在変数」に変換する「エンコーダー」と、潜在変数から入力データを復元する「デコーダー」の、二つの

ニューラルネットワークからなるネットワークである。

VAE では「潜在変数」が正規分布となることを仮定しているため、同傾向の入力データに対する潜在変数は設定した次元数の空間上にプロットすると近接して分布する。この特性を利用して、入力された加速器環境データに対する潜在変数を二次元に設定しプロットすることで、加速器環境データの分布傾向を可視化する。また、可視化した環境データを対応する加速器運転パラメータ値毎に着色することで、環境データと運転パラメータの相関関係も可視化する。図 3 に VAE の概略図を、図 4 に潜在変数の例を示す。なお、図 4 は0から9までの手書き数字画像(MNIST データ)を入力データとしてその潜在変数をプロットしたもので、元となった画像に対応する数




Figure 3: Example of VAE used in this study.




Figure 4: Example of latent variable.

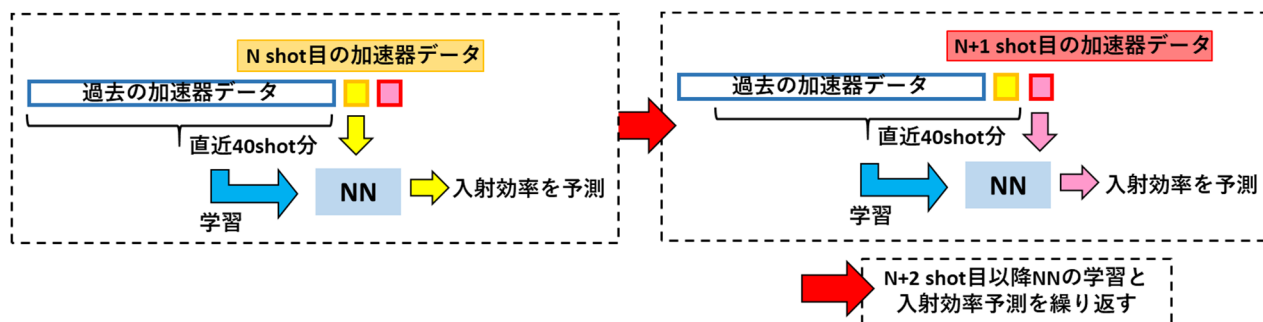


Figure 5: Outline of learning and prediction iteration.

字によって着色を行った。

### 3.2 入射効率の予測システム

本研究では、加速器環境データを入力として、そのデータから予測される入射効率の指標  $Q_{ratio}$  を出力するニューラルネットワークをデザインした。また、このネットワークについて、直近 40shot 分の環境データでの学習と、次 shot の環境データからの  $Q_{ratio}$  予測を時系列に沿って繰り返す。これは時間とともに変化する環境データの傾向に適応するためである。図 5 に学習と予測の概略を示す。

## 4. 加速器環境データの可視化

先述した加速器環境データについて 2018 年 11 月から 2019 年 12 月までに蓄積されたデータでかつ  $Q_{ratio}$  が 0.9 以上のものを VAE への入力データとして潜在変数を抽出した。なお、 $Q_{ratio}$  に注目したのは入射効率が良い状況における加速器環境データと運転パラメータの相関関係を検証するためである。

図 6 に VAE から得られた潜在変数の二次元プロットを示す。なお、相関関係の可視化のために、運転パラメータを値によって 7 分割し、環境データに対応する運転パラメータ分類毎に可視化結果を着色した。

分割した範囲は以下の通りである。

0. -0.6 未満
1. -0.6 以上、-0.4 未満
2. -0.4 以上、0 未満
3. 0 以上、0.2 未満
4. 0.2 以上、0.4 未満
5. 0.4 以上、0.6 未満
6. 0.6 以上

プロットから、以下三点を読み取ることができる。

- 2018 年～2019 年の加速器環境データの分布傾向を二次元の潜在変数で可視化することができた
- 入力した加速器環境データの振る舞い(潜在変数の分布)が時期によって異なっている
- 同じ加速器運転パラメータでも、対応する環境データの分布が時期によって異なっている

また、2018 年から 2019 年のデータで学習を行うことで、加速器環境データと運転パラメータの相関関係を二次元で記述する事ができたように見える。これについて、図 7 に学習済みの VAE に 2020 年 4 月の加速器環境データを入力して得られた潜在変数の二次元プロットを示す。

プロットから、2020 年の加速器環境データの潜在変数は、2019 年のデータで同じ運転パラメータ分類に対応している潜在変数に連続して分布していることが見て取れる。このことから、2020 年データと 2019 年データで同傾向の加速器環境データが同じ加速器運転パラメータに

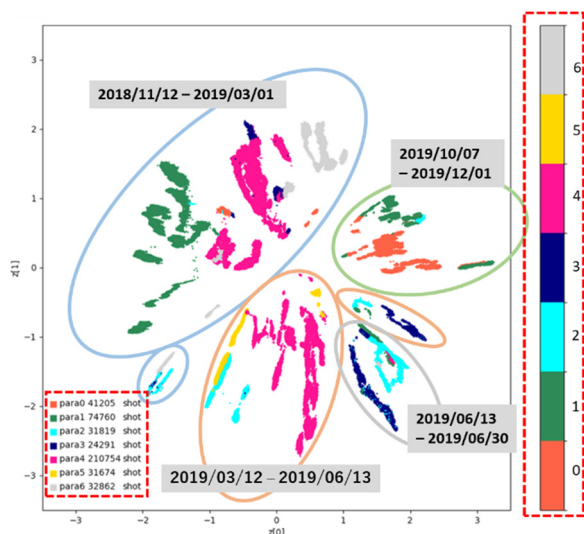


Figure 6: Latent variable of accelerator data (2018~2019).




Figure 7: Latent variable of accelerator data (2020).



対応していると考えられる。また、2018年から2019年のデータで学習を行ったVAEで加速器環境データと運転パラメータの相関関係を記述できたといえる。

## 5. 強化学習を導入した運転調整システム開発の準備研究

先述した加速器環境データについて2020年3月から2020年5月までに蓄積されたデータを入力データとして、入射効率の指標  $Q_{ratio}$  の予測を行った。図8に結果を示す。




Figure 8: Latent variable of accelerator data (2020).

横軸は入力データの時刻、縦軸は出力された入射効率の指標  $Q_{ratio}$  の値である。結果から、変化する加速器環境データの傾向に適応して入射効率の予測が可能であると分かった。

## 6. まとめ

本研究では、KEKで稼働中のLinac加速器の入射効率を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。加速器環境データ分布傾向と運転パラメータとの相関関係の時間変化についての検証と、強化学習を導入した運転調整システム開発の準備研究を行った。

加速器環境データと運転パラメータの相関関係の変化について調べるために、VAEを用いた環境データの可視化を行った。その結果、環境データと運転データの相関が時間の経過とともに異なっていることが明らかになった。一方で、2018-2019年に取得したデータで学習を行った場合は、2020年の加速器環境データと運転パラメータの相関関係を記述する事が可能であることが示された。

強化学習を導入した運転調整システム開発の準備研究として、直近の加速器環境データを入力し、入射効率予測値を出力するニューラルネットワークをデザインした。時系列に沿って直近のデータでの学習を繰り返すことで、加速器環境データの変化傾向に適応して入射効率の予測が可能であることが示された。

今後は今回の結果を踏まえて、入射効率を向上させるための、強化学習を用いた加速器パラメータ調整手法

の開発を進める。

## 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「加速器実験および関連分野への深層学習の適用と進化」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、および、山田科学振興財団の助成を受けて実施されました。

## 参考文献

- [1] H. Joan, M. Iwasaki, M. Satoh *et al.*, “機械学習を使用したKEK Linac 加速器運転調整システムの開発”, Proc. 16th Annu. Meet. Part. Accel. Soc. Japan, pp. 600–603, 2019.
- [2] K. Furukawa *et al.*, “同時トップアップ入射のためのKEK電子陽電子入射器の加速モード切替の高度化”, Proc. 17th Annu. Meet. Part. Accel. Soc. Japan, WEOOP01, 2020.
- [3] TensorFlow; <https://www.tensorflow.org/>
- [4] Keras; <https://keras.io/>
- [5] D. P. Kingma, and M. Welling, “Auto-Encoding Variational Bayes”, arXiv:1312.6114, 2014.