

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

R&D OF THE KEK LINAC ACCELERATOR TUNING USING MACHINE LEARNING

城庵颯^{#,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)}
Hayate Joan^{#,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 Dataability 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 an accelerator parameter tuning scheme using machine learning for the KEK e^-/e^+ injector linac (Linac). During the accelerator operations, various parameters are continuously optimized to get the high injection efficiency. To get more efficient and faster tuning scheme, and to improve the injection efficiency, we have designed a new accelerator tuning scheme by introducing the machine learning. The R&D for the new scheme is based on the accumulated Linac operation data (control parameters, monitoring data, environmental data), to see correlations between the injection efficiency and various accelerator parameters. In this paper, we report the current status of the study.

1. はじめに

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 では、常に高い入射効率を目指し、種々のマシンパラメータを調整し、その最適化を行っている。ここで、マシンパラメータの調整においては、

- 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、常に設定値の最適化を行わなければならない。
- 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。

という問題点がある。

上記の問題点に対して、我々は複数のパラメータ同士の複雑なパターン認識を得意とする機械学習に注目し、加速器のマシンパラメータの調整に機械学習を取り入れることで、

1. 加速器調整時間の高速化
2. 加速器調整性能の向上、安定化

が期待できると考えた。

したがって、我々は、加速器運転データを入力すれば、最適な加速器設定値を出力するようなニューラルネットワークをデザインして、実際の Linac 加速器運転データを用いて性能評価を行った。本稿では、これらの開発について、現状報告する。

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 50 Hz、2 バンチ (96 ns 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[1]。

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。




Figure 1: Accelerator placement at KEK.

また Fig. 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 200 台、RF モニターが 60 台配置されている。

[#] m18sa011@uv.osaka-uv.ac.jp




Figure 2: Layout of Linac.

3. ニューラルネットワーク

本研究では、ニューラルネットワーク(NN)を用いた機械学習を行った。ここでニューラルネットワークは、脳神経細胞ニューロンを模した基本単位と、そのつながりを数式的なモデルで表現したものである。中間層が多層になったものをディープニューラルネットワーク(DNN)と呼ぶ。

我々は、加速器運転データを入力すれば、入射効率が高くなるような加速器設定値を予測するような DNN をデザインした。Figure 3 に、本研究で使用した DNN を示す。

DNN の実装は、Tensorflow[2]および Keras[3]を用いて行った。




Figure 3: Example of DNN.

4. マシンパラメータの予測

Linac 加速器でのマシンパラメータの調整は大きく以下の 2 種類がある。

1. beam を通すための調整
2. beam の入射率を上げる調整

本研究では 2. を目的に開発を行った。

2018 年 11 月から 2019 年 3 月までに蓄積された、Super KEKB HER 用の Linac 加速器運転データを使用した。(1 nC 電子ビーム、36 日相当、データ数:1180500 shot)

収集データに含まれるパラメータの種類と数は以下の通りである:

- ビーム位置モニター (BPM) からのデータ (beam の位置、電荷量): 4600 個
- RF パラメータ (クライストロン の RF 位相とパワー): 340 個
- 電磁石パラメータ (電磁石励磁電流値読み返し値): 811 個
- 環境パラメータ (環境温度、冷却水温など): 732 個
- ユーティリティ情報 (機械室の冷却水ポンプ圧力など): 324 個

本研究では高い入射効率を得るための指標として、Linac 加速器の上流、下流、それぞれの BPM における beam の電荷量の比、 Q_{ratio} を用いた。

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

Figure 4 に本研究で使用した DNN の図を示す。加速器運転データを入力すれば、最適な加速器パラメータを出力できるような DNN を作成するため、 Q_{ratio} の値が高いデータを用いて、DNN (回帰又は分類) の学習を行った。



Figure 4: Example of DNN used in this study.

以下に、本研究で構築した DNN の構成を示す。

- 環境パラメータ (環境温度、冷却水温など): 732 個
- epoch 数 : 50
- batch size : 1000
- optimizer : Adam (学習率=0.001)
- loss 関数 : mean squared error (回帰)
categorical cross entropy (分類)
- 中間層の数 : 5 層
- drop out 層 : 1 層

4.1 RF 位相パラメータの予測

Figure 5 に、RF 位相パラメータと Q_{ratio} の 2 次元プロットを示す。図に示されている通り、 Q_{ratio} が高くなるような RF 位相パラメータはばらついていて、したがって、環境パラメータ等のデータによって、 Q_{ratio} が高くなるような RF 位相パラメータを予測するための DNN を開発した。

本研究では、B Sector 5 個目のクライストロン出力の RF 位相パラメータに注目し、 Q_{ratio} が 0.85 以上のデータを用いて開発を行った。

最初に、回帰問題として DNN の学習を行ったが、正しく RF 位相パラメータを予測することが出来なかった。

したがって、Fig. 5 のようにデータを 6 分割し、分類 (識別) 問題として DNN の学習を行った。分割した範囲は、以下の通りである:

0. 0.1 未満
1. 0.1 以上、0.2 未満
2. 0.2 以上、0.3 未満
3. 0.3 以上、0.4 未満
4. 0.4 以上、0.5 未満
5. 0.5 以上

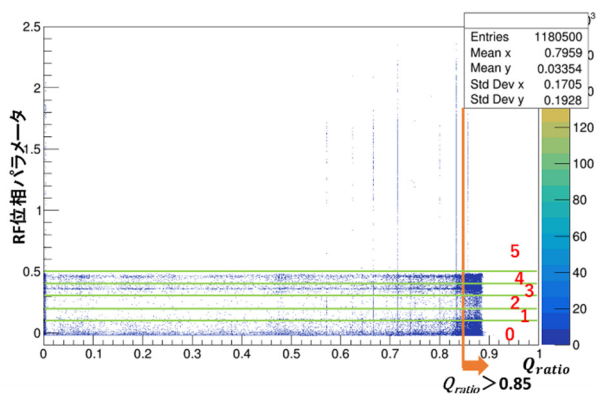


Figure 5: Relationship between RF phase and Q_{ratio} .

Table 1: Relationship between true value and predicted value when only environmental parameters are input to DNN.

		予測値					
		0	1	2	3	4	5
真値	0	2021	0	0	0	0	0
	1	2	638	290	25	239	115
	2	2	134	1138	80	82	131
	3	60	61	255	123	874	14
	4	68	36	86	41	1007	19
	5	0	523	651	28	6	205

Table 2: Relationship between true value and predicted value when environmental parameter and RF parameter are input to DNN.

		予測値					
		0	1	2	3	4	5
真値	0	2019	2	0	0	0	0
	1	2	1308	45	0	0	0
	2	0	288	1235	43	1	0
	3	0	0	38	1315	33	1
	4	0	0	0	121	1134	2
	5	1	0	0	0	18	1394

DNN への入力パラメータとして、i) 環境パラメータのみ、ii) 環境パラメータ+評価に使用していない RF パラメータ、の 2 種類について性能評価を行った。Table 1、および Table 2 に、それぞれ i)、ii)の結果を示す。これらの表は、RF 位相パラメータの真値と、学習後に DNN が出力した予測値の関係を示す。

予測値に対する正答率は、i) 57%、ii) 93%となった。したがって、RF 位相パラメータは、環境パラメータ、および、評価に使用していない他の RF パラメータと強い相関があり、それらのパラメータを用いて学習した DNN から、最適なパラメータの予測が可能だということがわかった。

4.2 ステアリング電磁石パラメータの予測

Figure 6 に、ステアリング電磁石パラメータと Q_{ratio} の二次元プロットを示す。RF 位相パラメータの場合と同様、

Q_{ratio} が高くなるようなステアリング電磁石パラメータはばらついている。

したがって、RF 位相パラメータの場合と同様に、環境パラメータ等のデータによって、 Q_{ratio} が高くなるようなステアリング電磁石パラメータを予測するための DNN を開発した。

本研究では、4 Sector 6 個目のステアリング電磁石パラメータに注目し、 Q_{ratio} が 0.8 以上のデータを用いた。

最初に、回帰問題として DNN の学習を行ったが、正しくステアリング電磁石パラメータを予測することが出来なかった。したがって、Fig. 6 のようにデータを 5 分割し分類問題としての DNN の学習を行った。分割した範囲は以下ようになる。

0. 0 未満
1. 0 以上、0.5 未満
2. 0.5 以上、1 未満
3. 1 以上、1.5 未満
4. 1.5 以上

DNN への入力パラメータとして環境パラメータ、RF パラメータ、そして電磁石パラメータ、全てを入力しても正答率が 31%となり、今回の手法では、正しい予測値を得ることができなかった。

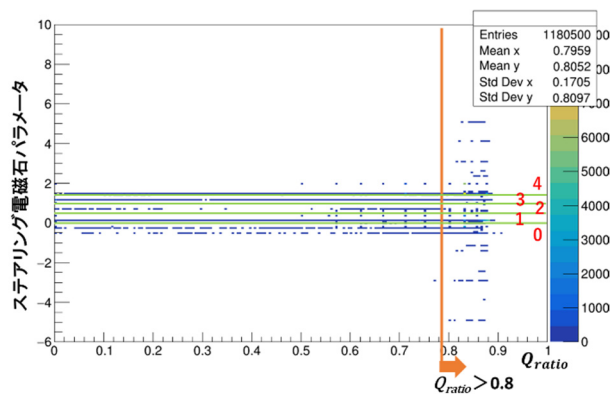


Figure 6: Relationship between Steering Magnet and Q_{ratio} .

さらに、同様の方法で、他の 2 か所のステアリング電磁石パラメータについても DNN による学習を行ったが、最適な入射効率を得るためのパラメータを、正しく得ることが出来なかった。

したがって、ステアリング電磁石パラメータに関しては、RF 位相パラメータとは異なり、環境パラメータや、他のステアリング電磁石パラメータ、RF 位相パラメータとの相関がないことがわかった。

5. まとめ

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を行った。

高い入射効率を得るための加速器パラメータを予測するための DNN を構築し、Linac 加速器運転データを用いて、性能評価を行った。

RF 位相パラメータの調整については、環境パラメータと RF パラメータから、RF 位相パラメータ最適値を予測す

ることが出来た。しかし、ステアリング電磁石パラメータの調整については、環境パラメータや、電磁石パラメータ、RF パラメータから予測することができなかった。

したがって、ステアリング電磁石パラメータの調整を行うためには、強化学習等、さらに異なる機械学習を用いた開発が必要だと考えられる。

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、大阪市立大学戦略的研究(基盤研究)の助成を受けて実施されました。

参考文献

- [1] R. Zhang *et al.*, “KEK 電子陽電子入射器の現状”, in Proceedings of the 16th Annual Meeting of Particle Accelerator Society of Japan, Kyoto, Japan, Jul.
- [2] TensorFlow: <https://www.tensorflow.org/>
- [3] Keras: <https://keras.io/>