

機械学習を用いた J-PARC RCS 用ペイントバンブ電源の波形パターン制御

WAVEFORM PATTERN CONTROL OF PAINT BUMP POWER SUPPLY FOR J-PARC RCS USING MACHINE LEARNING

杉田萌^{#, A)}, 高柳智弘^{A)}, 植野智晶^{B)}, 小野礼人^{A)}, 堀野光喜^{B)}, 金正倫計^{A)}, 小栗英知^{A)}, 山本風海^{A)}

Moe Sugita^{#, A)}, Tomohiro Takayanagi^{A)}, Tomoaki Ueno^{A)}, Ayato Ono^{A)}, Koki Horino^{A)},

Michikazu Kinsho^{A)}, Hidetomo Oguri^{A)}, Kazami Yamamoto^{A)}

^{A)} Japan Proton Accelerator Research Complex (J-PARC)/Japan Atomic Energy Agency (JAEA)

^{B)} Japan Proton Accelerator Research Complex (J-PARC)/NAT corporation (NAT)

Abstract

In J-PARC RCS, paint bump magnets are used to displace the beam orbit during paint injection, which produces a high intensity beam. A pattern of command current and command voltage can be used to create an output current waveform that varies the beam orbit over time. The accuracy of beam orbit control is determined by the shape difference between the command current and output current waveforms. In the current paint pattern adjustment, a deviation of $\pm 1\%$ or less is achieved by manual adjustment after using software that adjusts the pattern according to the response function of the power supply control. However, we would like to reduce the adjustment time. In addition, since the accuracy of paint injection is determined by the adjustment system of the paint magnet power supply, we would like to achieve output current deviation 10 times more precise than before to reduce beam loss. An analytical model of the load-side impedance is necessary to create a high-precision paint pattern, but it is very difficult to construct an analytical model because the load-side impedance changes in a time-varying nonlinear paint pattern. We used machine learning to adjust the output pattern of the paint pattern and achieved a deviation of less than $\pm 0.5\%$ through repeated learning. This presentation will report on the current status of the system and its prospects.

1. はじめに

J-PARC[1] RCS[2]では、大強度ビームを生成するペイント入射[3]において、ビーム軌道を変位させるためにペイントバンブ電磁石を用いている。ペイントバンブ電磁石用の電源は、IGBT 制御のチョッパ回路で構成され、指令電流と指令電圧のパターンの入力により、ビーム軌道を時間変化させる出力電流波形(ペイントパターン)を生成している(Fig. 1)。ビーム軌道の入射精度は、指令電流値と測定した出力電流値の波形形状差(出力電流偏差)で決まる(Fig. 2)。現在のペイントパターンの調整方法は、電源制御の出力応答特性に着目し、目的とする指令電流値に応じた指令電圧値を算出するソフト[4]と、出力電流偏差を確認しながら指令電圧値をその都度調整する手動調整を組み合わせで行っている。この方法により、ペイント入射に必要なビーム入射部の偏差 $\pm 1\%$ を達成している。しかし、RCS の更なる大強度化に向け、より高精度なペイント入射が要求されている。そこで、本研究では、機械学習を用いたペイントパターン調整を検討し、より高精度なペイント入射の実現を目的とする。

指令電流に応じた電圧指令値は、負荷インピーダンスで決まる。電源から見た負荷の電磁石と電力伝送ケーブルのインピーダンスは、時間変化する非線形のペイントパターンの形状に応じて異なるため、パターン毎に指令値の調整が必要となっている。

そのため、短い時間で最適な指令電流値を算出するためには、電源制御の出力応答特性の理解に加え、ペイントパターンの形状に応じた負荷インピーダンスの過

渡解析モデルを必要とする。

しかし、RCS のペイントバンブは、大強度ビームの加速器運転において、物質・生命科学実験施設(MLF)[5]や、主リングシンクロトロン(MR)[6]用のビーム運転に求められるペイントバンブパターンは多数ある(Fig. 1)。さらに、ビーム運転中にペイント入射軌道を調整する場合もあるため、急なペイントパターン調整も求められる。以上のことから、パターン毎に解析モデルを構築することは現実的ではない。

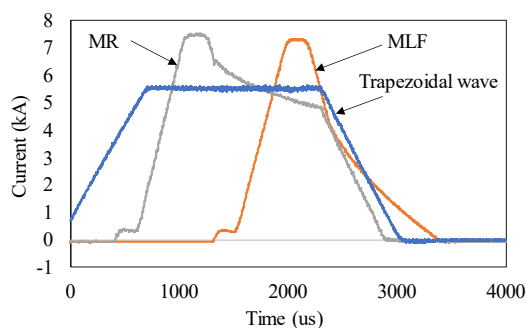


Figure 1: Paint bump power supply waveform patterns.

そこで、負荷の解析モデルを構築せずとも、ペイントパターン調整の学習によって非線形な応答を高速かつ高精度で得ることが可能な機械学習の使用を検討する。ペイントパターンのうち、ビーム軌道確認などに使用する形状変化が少ない台形型パターンを使い、機械学習を用いたペイントパターン調整を試験的に行った。本発表で

[#] moe.sugita@j-parc.jp

は、使用した機械学習システムの仕様と試験結果、今後の展望について報告する。




Figure 2: Command value for painting waveform pattern (V-Pattern, I-Pattern), output value of current (CT) and deviation (1 V=1 kA).

2. ペイントパンプ電磁石電源の概要

2.1 電源の構成

ペイントパンプ電源は、IGBT アセンブリを直列と並列に多重に組み合わせた並列多重の二象限チョッパ回路で構成されている。IGBTは1アセンブリ当たり54kHzで動作し、これを12多重化することで648kHzの高速スイッチングによる波形合成が可能である[7, 8]。さらに、MLF用とMR用として別々に要求された異なるペイントエリアでの入射スキームに、25Hzで励磁波形を切り替える運転も可能である。

ペイントパンプ電源の出力電流は、指令電圧値を変換したIGBT制御信号によってアナログ制御される。この制御信号は、電流フィードバックと電圧フィードフォワードによって生成される。制御回路は、電流フィードバックとして、出力電流が指令電流と一致するように連続的に指令電圧値を決定し、IGBT制御信号を生成する。しかし、電流フィードバックの応答時定数は20μs程度であるため、ビーム入射時間500μsという短い時間で電流値が連続的に大きく変化する場合、出力電流が指令電流から逸脱する。そこで、電圧フィードフォワードとして、指令電流波形に基づいて負荷回路全体のインダクタンスと抵抗から求められる設定電圧を制御回路に直接投入している。

2.2 波形パターン

水平ペイントパンプ電源用の波形パターンは、12bitのデジタル信号として、指令電圧と指令電流を500kHz(2μs)で作成する。また、指令電流値と指令電圧値は0から2048、2049から4096をそれぞれ±10Vに割り当て、29kA=10V、1.2kV=10Vとしてパターンを作成する。出力する電流と電圧が定格の範囲内であれば、任意の波形形状での出力が可能である。

2.3 出力電流の調整方法

ペイント電磁石電源の出力電流の調整では、電圧フィードフォワードに使用している指令電圧の調整を行う。まず、単純な $V = L_m(di/dt) + R_m i$ (L_m , R_m はそれぞれ負荷回路全体のインダクタンスと抵抗)の式より求めた指令電圧を用いて通電し、出力電流を得る。そして、出力電流偏差が0となるように設定電圧の一部を変化させる。これを繰り返し行うことで、出力電流偏差を最小化していく。

3. ベイズ最適化によるパターン最適化

3.1 ベイズ最適化

ブラックボックス関数の最適化に用いられるベイズ最適化[9]を用いて探索を行った。ベイズ最適化は、最適化を行いたい目的関数が陽に与えられず、実験的に結果が得られるような場合に、ガウス過程回帰によって実験データ点から関数系を学習しつつ、その関数の大域的最適解の探索を行う手法である。そのため、可能な限り少ない実験回数でブラックボックス関数を最適化できるという利点がある。

ガウス過程回帰は、入力 x と出力 y の間にある関数 $y=f(x)$ を推定する手法である。ガウス過程回帰の特徴として、入力の集合 $X^n = \{x_i\}_{i=1}^n$ が与えられたとき、対応する出力 $Y^n = \{y_i\}_{i=1}^n$ が多変量ガウス分布に従うという点がある。そのため出力 y の推定幅が算出される。ベイズ最適化では、この推定幅を用いて次の入力の候補点を算




Figure 3: Dividing trapezoidal waves into sections.

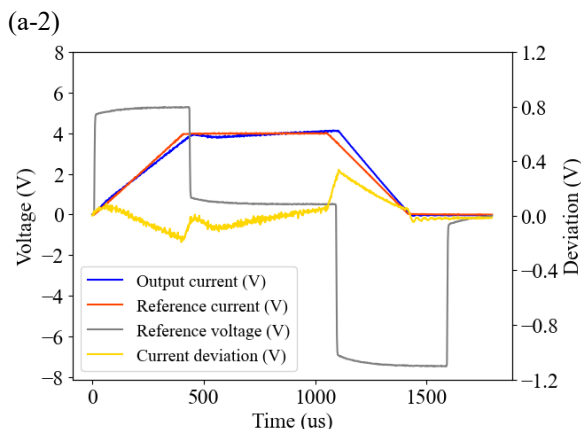



Figure 4: Waveform of trial (a).





Figure 5: Waveform of trial (b).

出する。

予測値と実験値の差を用いて、モデルがデータと乖離が無いか確かめる。予測値と実験値の差を評価するために、偏差の絶対値の平均値である平均絶対誤差 MAE(eq. 1)を用いた。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (1)$$

y_i : i 番目の電流予測値
 \hat{y}_i : i 番目の電流実験値

3.2 ペイントバンブ電磁石波形パターン最適化

ビーム入射期間の MAE が±1.0%以内となるパターンの探索を、ベイズ最適化を用いて行う。パターン波形は、簡単のために台形波形パターンを用いた。立ち上げ時間 400 μs、フラットトップ時間 600 μs、立下げ時間 360 μs で、ビーム入射期間は $t=500\sim 1000$ μs の 500 μs とする (Fig. 3)。また、実験に用いた電源はペイントバンブ電源先行機で、オフライン試験とした。

試行した内容を次に示す。

(a) 電源電圧を区間①立ち上がり部、区間②フラットトップ部、区間③立下り部の 3 区間に分け、パラメータを区間の長さで電圧値の $3 \times 2 = 6$ パラメータとする (Fig. 3 上図)

(a-1) 各区間で MAE が小さくなるよう探索

(a-2) 全領域の MAE が小さくなるよう探索

(b) 電源電圧を区間①立ち上がり部、区間②フ

ラットトップ部、区間③立下り部の 3 区間に分け、フラットトップ部の重み(影響度の大きさ)を最大に設定して探索 (Fig. 3 上図)

(b-1) 重みを区間①:区間②:区間③=1:5:4 に設定
(b-2) 重みを区間①:区間②:区間③=1:50:40 に設定

(c) 電源電圧を区間①立ち上がり部、区間②-1 フラットトップ部前半、区間②-2 フラットトップ部後半、区間③立下り部の 4 区間に分け、フラットトップ部の重みが最大の状態で探索 (Fig. 3 下図)

Table 1: Description of Trial and MAE Values

Trial No.	MAE (kA)			
	Section①	Section②	Section③	Total
a-1	0.17	4.87	2.10	7.23
a-2	2.06	0.94	10.85	14.48
b-1	0.53	4.54	28.99	34.37
b-2	0.77	6.70	18.88	26.50
c	14.96	0.11	14.58	30.90

Table 1 および Fig. 4 より、試行(a)の 2 つの結果を比較すると、試行(a-1)よりも(a-2)の方がフラットトップ部の

MAE が小さくなったことが分かる。ビーム入射期間の偏差を小さくするためには試行(a-2)のようにすべての領域でMAEが小さくなるよう探索を行うが適当であるといえるため、以降の探索は(a-2)と同様の手法で探索を行う。

次に、試行(b)では各区間の重みづけを行い、フラットトップ部の重みを最大とした。しかし、試行(b-1)、(b-2)ともに試行(a)よりもフラットトップ部の MAE が増加した。これは、フラットトップ部の頭は立ち上がり部の後半の影響を受けるため、オーバーシュートが発生し、誤差を生んでいると考えられる(Fig. 5)。

そこで、フラットトップ部を 2 区間に分け(Fig. 3 下図)、立上がり部からフラットトップ部に切り替わる区間の重みを大きくする試行(c)を実施した。すると、ビーム入射期間の MAE を小さくすることに成功した。偏差を抑えたいビーム入射期間の直前を精度よく調整することで、ビーム入射期間の偏差を減らせることが分かった(Fig. 6)。

計 680 回試行したところ、Fig. 7 より 492 回を超えてからビーム入射期間の MAE が 0.01(偏差: $\pm 0.5\%$)を下回る指令電圧が探索されるようになった。




Figure 6: Waveform of trial (c).




Figure 7: Change in MAE versus number of trials.

4. まとめと今後の展望

RCS の更なる大強度化に向け、より高精度なペイント入射が要求されている。そこで、機械学習(ベイズ最適化)を用いて、 $\pm 1.0\%$ 以下の要求精度を達成するペイントバンプ波形調整を行った。指令電圧の区間を、区間①

立ち上がり部、区間②-1 フラットトップ部前半、区間②-2 フラットトップ部後半、区間③立下り部の 4 つに分け、ビーム入射期間の直前である区間②-1 の重み(影響度の大きさ)を大きくしたことで、ビーム入射期間の偏差を $\pm 0.5\%$ 以内に収めることができた。

本研究において、複数あるペイントバンプ波形のうち台形波のパターン最適化を行うことができた。今後、Fig. 1 に示す MLF 波形や MR 波形の最適化も行っていく。この手法が確立すれば、経験者のノウハウに頼らない調整と、調整時間の短縮、さらには、ビーム軌道変位に起因したビームロスの更なる低減として、ペイント入射軌道の $\pm 0.2\%$ 以下の高精度化も実現できると考えている。

謝辞

計算コードの開発にあたり、日本電気株式会社の皆様に多大なるご協力をいただきました。深く感謝申し上げます。

参考文献

- [1] Japan Proton Accelerator Research Complex J-PARC, <http://j-parc.jp/index.html>
- [2] K. Yamamoto *et al.*, "Design and actual performance of J-PARC 3 GeV rapid cycling synchrotron for high-intensity operation", *Journal of Nuclear Science and Technology*, (2022), 59:9, 1174-1205.
- [3] H. Hotchi *et al.*, "Beam Dynamics Study for Beam Loss Mitigation in the J-PARC RCS" *J. Particle Accelerator Society of Japan*, Vol. 16, No. 2, 2019, pp. 109-118.
- [4] S. Kato *et al.*, *Proceedings of the 12th Annual Meeting of Particle Accelerator Society of Japan (PASJ2015)*, August 5-7, 2015, Tsuruga, Japan, THP075.
- [5] J-PARC MLF, <https://mlfinfo.jp/ja/>
- [6] J-PARC Main Ring, <https://j-parc.jp/c/facilities/accelerators/mr.html>
- [7] T. Takayanagi *et al.*, *IEEE Transactions on Applied Superconductivity*, VOL. 24, NO. 3, JUNE 2014, 3800905.
- [8] T. Ueno *et al.*, "Status of the horizontal paint bump power supply of the J-PARC RCS", *Proceedings of the 11th Annual Meeting of Particle Accelerator Society of Japan August 9-11, 2014, Aomori, Japan, PASJ2014-SUP058*.
- [9] B. Shahriari *et al.*, "Taking the Human Out of the Loop: A Review of Bayesian Optimization," in *Proceedings of the IEEE*, vol. 104, no. 1, pp. 148-175, Jan. 2016.