

## 機械学習の適用によるビーム不安定性の判定と対策

### APPLICATION OF MACHINE LEARNING TO JUDGE AND COUNTER BEAM INSTABILITY

小林愛音<sup>\*,A)</sup>, 外山毅<sup>A)</sup>

Aine Kobayashi<sup>\*,A)</sup>, Takeshi Toyama<sup>A)</sup>

<sup>A)</sup> KEK

#### Abstract

Machine learning is increasingly applied in accelerator research, but its use in high-intensity proton facilities such as J-PARC main ring requires caution, as collecting large datasets or failed trials can cause equipment activation and damage. This study aims to minimize beam loss—a key challenge in beamline optimization—through three approaches: (1) detecting anomalies via numerical analysis, (2) detecting abnormal beam events using trained image-based models, and (3) optimizing intra-bunch feedback system parameters to suppress transverse instabilities using log data. The goal is to support real-time anomaly detection during J-PARC MR shifts and, in the future, enable diagnostics of beam loss causes and early signs of equipment issues. Automating the tuning of feedback parameters, which is currently manual and time-consuming, can enhance beam intensity and availability. This report presents the current progress of these developments.

#### 1. はじめに

近年、加速器研究において機械学習の応用が進展している。しかしながら、大強度陽子加速器においては、学習に必要な統計量の確保や試行錯誤に伴うビームロスの増加が、装置の放射化や損傷を引き起こすリスクを伴うため、実用化には慎重な対応が求められる。粒子加速器におけるビームの安定性は、稼働率の向上、装置寿命の延伸、物理実験の精度確保において極めて重要な要素である。特に、異常なビームロスや出力低下を伴うイベントを早期に検出し、制御パラメータの最適化を図ることは、加速器運用の高度化に資するものと考えられる。本報告では、(1) 数値統計に基づく異常検出、(2) 画像診断の機械学習応用、(3) 横方向ビーム不安定性抑制のためのイントラバンチフィードバック装置 (IBFB) [1] の設定値最適化、という3つのアプローチを用いてビーム異常の検知と最適化を試みた。

本研究では、機械学習の実装に PyTorch [2] を用いた。PyTorch は柔軟で直感的な記述が可能な深層学習ライブラリであり、研究用途での試行錯誤やモデル構造の調整が容易であることから、異常検知や回帰モデルの構築に適している。また、GPU を用いた高速な学習処理にも対応しており、大量のデータを扱う加速器システムにおいて有効な基盤となる。

#### 2. 数値統計に基づく異常検出

ショット毎のビーム出力パワーとバンチ数の関係を調べ、統計的に平均から外れたイベントを抽出する手法を検討した。具体的には、バンチ数で規格化したビームパワー (正規化ビームパワー) が平均より小さいショットを異常とみなす単純なルールを導入した。Figure 1 はビーム調整やスタディを含むある期間のバンチ数で正規化ビームパワーを示しており、バンチ数に対してビームロスが多かったショットを判別できる。これらの値は EPICS レコード [3] としてアーカイブされたものを取得している [4]。ここでは例えば平均より  $0.75\sigma$

小さいものを異常と設定することで判定できる。閾値の取り方は異常イベントの多い期間を平均化して基準にしてしまうと正しく診断できなくなるため注意が必要である。また、今後入射エラーに対しても考慮を検討する。数値統計を使う場合は、ビームパワーだけでなくバンチの入射タイミングでの粒子数や DCCT [5, 6] の波形などを使うことも考えられる。既にビームロスの値で MPS (Machine Protection System) [7] を設定し利用されているのでそれ以上の実用性を考える必要がある。

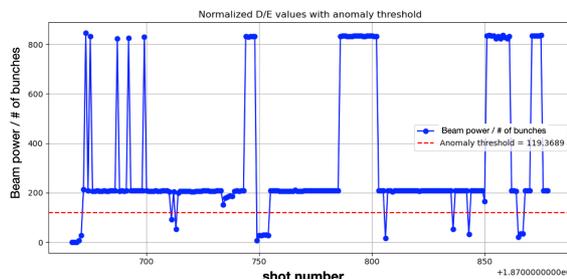


Figure 1: Beam power normalized by bunch count over a given period. Values  $0.75\sigma$  below the mean are regarded as anomalies.

#### 3. 画像診断による異常検出

ビームロスモニター [8] 画像を畳み込みオートエンコーダー (CAE : Convolutional Autoencoder) [9, 10] を用いて教師なしで学習し、再構成誤差から異常イベントを自動で検出する手法を検証した。

Figure 2 はメインリング運転中に使用されているビームロスモニターのカウンタ表示例であり、佐藤健一郎氏により開発されたモニターから読み出した信号の画面を用いて制御担当の山田秀衛氏により作成されたものである。左上のプロットは DCCT の波形を示し、2バンチずつ4回に分けてメインリングへ入射されたことが確認できる。左下のプロットは、横軸にメインリング全周に配置されたビームロスモニターのアドレス、縦軸に入射からの経過時間をとった2次元分布である。

\* aine.kobayashi@kek.jp

正常なイベントでは、ビームロスには主にコリメーター領域に局在しており、出射部で若干のロスが見られる他は、全体としてビームロスは少ない傾向にある。他の4つのプロット群は、メインリング入射前の3-50ビーム輸送ラインにおけるロスや、ビームロスモニターデータの別視点からの可視化を示している。これら6種類のどれが効いているのか、一部だけ使用した方が効果的か他にも情報を入れたらどうなるか、図の元である数値情報をインプットにしたほうがよいか、などは今後調べる予定である。今回は試行錯誤の最初の段階として普段人が見ている画面をそのまま保存して使ってみることにした。

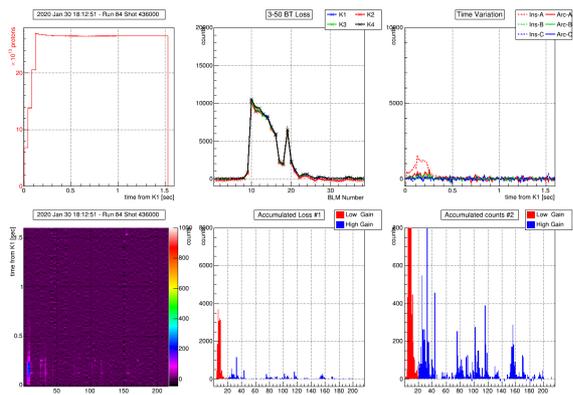


Figure 2: Example of beam loss distribution in a normal event. This shot includes 8 injected bunches.

### 3.1 畳み込みオートエンコーダーによる出力予測モデルの構築

学習には正常イベントのみを用いた。最初にオートエンコーダーを試したが異常データに対する正答率が低かったので、畳み込みオートエンコーダーを用いることにした。ここで、オートエンコーダーとは画像などのデータを圧縮し復元する仕組みを使った自己学習型 AI モデルで、うまく元に戻せるものを正常データ、うまく戻せないものを異常データと判断した。単なるオートエンコーダーは画像を1次元まで圧縮するが、畳み込みオートエンコーダーは画像をそのまま使い、画像内の局所的特徴を保持可能という特徴がある。

CAE は、Encoder 部と Decoder 部から構成されており、入力画像を圧縮して特徴ベクトルを抽出し、再度元の画像に復元する構造を持つ。Encoder 部では、1チャンネル・64×64ピクセルの入力画像に対し、畳み込み層(Conv2D)と活性化関数 ReLU を4層重ねることで、空間情報を圧縮しつつ抽象的な特徴を抽出した。各層においてチャンネル数を増やし、画像サイズはストライド2で1/2ずつ縮小され、最終的に(8, 4, 4)のボトルネック表現に到達させた。Decoder 部では、このボトルネックから ConvTranspose2D (逆畳み込み) 層によって空間解像度を段階的に復元する処理を行い、最終的に入力と同サイズ(1, 64, 64)の再構成画像を出力させた。Decoder の最終層では、出力値を0~1に正規化するために Sigmoid 関数を用いた。CAE は入力画像と再構成画像との画素ごとの差(再構成誤差)を計算し、これ

を異常判定の基準とした。学習には正常な画像のみを用い、モデルは正常画像の構造を忠実に再構成する能力を獲得させる。一方、異常画像に対しては訓練された再構成能力が通用せず、復元誤差が大きくなる。この再構成誤差を用いて異常の有無を定量的に判断した。再構成誤差が平均より大きく、ある閾値を超える場合に異常と判定した。今回は閾値は再構成誤差の平均に標準偏差の3倍を加えた値(mean + 3σ)とした。

### 3.2 学習成果による異常検知

学習後に複数の画像を読み込んで再構成誤差分布を比較した結果、Fig. 3 に示すように正常ショットと異常ショットが明確に分離して分類でき、本手法による異常検知の有効性を示している。ここで青色が正常画像、赤色が異常画像である。赤色の異常画像の分布が再構成誤差が小さいものから大きなものに4つに分かれたのでその内訳を調べると、Fig. 4 に示すように、再構成誤差が悪くなるにつれてビームロスが多くなっていた。

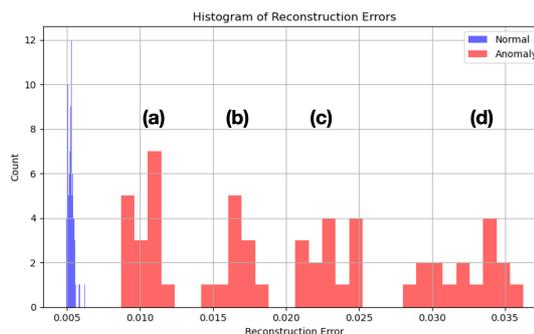


Figure 3: Distribution of reconstruction errors. Normal and anomalous shots are clearly separated, demonstrating the effectiveness of the proposed anomaly detection method.

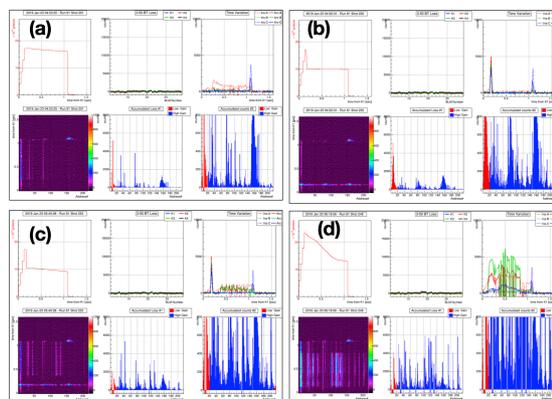


Figure 4: Examples of images corresponding to the histogram distributions (a) - (d) shown in Fig. 3.

### 3.3 課題

前章で述べたことと同様に、ビームロスが大きなショットはビームロスモニターの MPS で検知できるた

め、この研究の最終目的は単なる異常検知ではない。今後、ビームロスの由来（共鳴、装置故障、設定ミス等）を判別できることや、MPS にかからない微妙な異常または異常の兆候の検出をできるようにしたい。そのためには、画像収集を行い、由来毎の特徴を検出する分類精度の向上が課題である。ここで人が判断したバイアスが入らない客観的分類をする必要があると考えている。

#### 4. 機械学習による IBFB 設定最適化

この研究では、ログファイルから取得した IBFB の設定値 (gain, phase, shift gain) とビームパラメータ (バンチ数およびビームパワー) およびビームロス画像との関係を教師あり学習によってモデル化し、正規化ビームパワーを最大化する最適な設定の導出を試みた。

IBFB には現在 Dimtel 社 [11] の製品を使っており設定パラメータは、数ミリ秒ごとの「state」と呼ばれる 16 個のタイミングで切り替えられる仕組みとなっている。各 state に対して 4 種類の coeff set と呼ばれる設定 (その中身は gain, phase, frequency, taps) から 1 つを選択する仕様である。さらに、各 state ごとに「shift gain」と呼ばれるパラメータにより、gain に対して  $2^n$  倍のスケールを適用することが可能である。他にも fidutial delay や back-end delay など遅延量を変えてタイミングを調整するパラメーターもあるが今回は固定とした。その他、全体のタイミングを制御するパラメータも存在するが、本研究では設定空間を限定するため、frequency および taps は固定とし、gain > 0 の coeff set を 1 つのみ使用した。その上で、coeff set の gain, phase, および各 state の shift gain という 3 つのパラメータに着目し、これらを機械学習により最適化する手法を試した。

##### 4.1 マルチモーダル深層学習による出力予測モデルの構築

本研究では、EPICS システムから取得されるログデータとスクリーンショット画像を統合的に用いたマルチモーダル学習モデルを構築した。具体的には、X と Y 方向それぞれの gain · phase · shift gain からなる 6 次元の数値データと、ビームロスモニターのスクリンショット画像を入力とし、正規化ビームパワーを予測するニューラルネットワークを学習した。画像からの特徴抽出には、畳み込みオートエンコーダ (CAE) を用い、CAE のエンコーダ出力 (128 次元) と数値特徴 (6 次元) を結合し、全結合層によって出力値を回帰するフュージョン回帰モデルを構成した。ここでフュージョン回帰モデルとは複数の種類の情報を組み合わせて、それらをもとに数値を予測するモデルのことである [12]。学習のエポック数に対する再構成誤差 (MSE loss) の推移は、例えば Fig. 5 に示すようになった。全データの 80 % を訓練用、残り 20 % を検証用に用いており、図中の青線は訓練データに対するロス、オレンジ線は検証データに対するロスを示す。学習の進行に伴って両者のロスが低下し、一定のエポック数で収束傾向を示すことから、過学習を避けつつ有効な特徴抽出が行われていると考えられる。

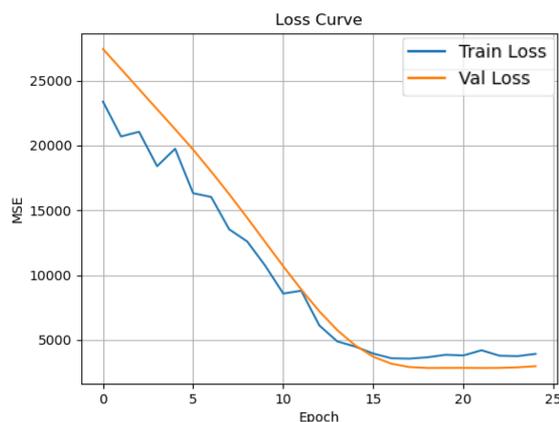


Figure 5: The blue line shows the reconstruction loss on the training dataset (80 % of total data), and the orange line shows the loss on the validation dataset (remaining 20 %).

##### 4.2 ベイズ最適化によるパラメータ空間の探索

学習済みモデルを用い、6 つのパラメータに対する最適化を実施した。ここで、gain ∈ [0, 1]、phase ∈ [-180, 180]、shift gain ∈ {0, 1, 2} とし、探索空間に制限を加えた (実際には shift gain は 7 まで可)。与えたスクリーンショット画像 1 枚を CAE の入力とし、対応する特徴量を固定した上で、scikit-optimize (skopt) ライブラリを用いたガウス過程ベイズ最適化 (gp\_minimize) によって、ビーム出力が最大となる設定値を推定した。評価関数には、フュージョン回帰モデルが出力するビーム出力の予測値を使用し、出力の最大化問題として定式化した。

得られた最適値の例としては、Fig. 6 の画像に対し、Table 1 が得られた。ここで X と Y はデータ取得当時、hybrid coupler の位相が逆転していたためそれが反映された結果になった。

このように少数データ環境でも CAE を活用した画像特徴と数値設定の融合により、出力予測モデルを構築できる。ベイズ最適化により現実的な最適設定が得られ、今後統計を増やして評価や改良を進める。

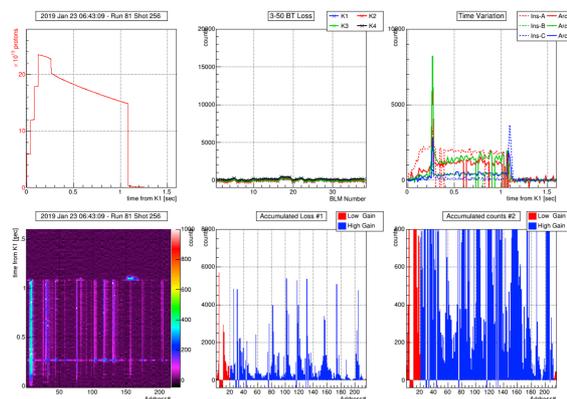


Figure 6: An example of predicted optimal parameters for a case not used during training.

Table 1: Example of the Optimized Parameter Set Obtained from the Trained Model

	gain	phase	shift gain
X	5.00	180	2
Y	5.00	-180	2

### 4.3 課題

本研究で対象とした IBFB に関連する EPICS レコードは、現時点ではアーカイブシステムに記録されておらず、ビームスタディ時における IBFB 調整の都度、個別にスクリプトを作成してデータをログファイルとして記録した。記録できた調整は3回分、計約100ショット分であるが、その多くはパラメーター変更による抑制効果が不十分な試行も含まれている。今後、抑制効果が十分に得られた調整結果も含めて統計を蓄積する必要があり、次回以降のビーム調整においても記録の継続を行う予定である。なお、アーカイブに保存されていないため、過去の調整結果については手書きのログノートや操作画面のスクリーンショットをもとに情報を抽出する必要がある。ビームタイム外の期間においては、パラメーターの影響を簡易的に再現可能なシミュレーション環境の構築も検討している。

注意すべき点として、機械学習によって導出された設定値を自動的にビーム調整へ適用することは、安全上の観点から避けるべきである。万が一、不適切なパラメータが選択された場合、大きなビームロスを引き起こし、機器の損傷や放射化のリスクが高まる可能性がある。また、手動による調整を行う場合においても、初めから最大バンチ数で実施することは危険であり、まずは少数バンチで安全性を確認した上で、段階的にバンチ数を増加させる必要がある。

## 5. 今後の展望

より微細な異常の検出を目指ために異なる原因により発生したビームロスに関する多数のショット画像を収集し、可能な限り人為的なバイアスを排除した分類手法を確立する。ビーム調整や利用運転中に利用可能なアプリケーションの開発を進め、リアルタイムでの異常検知および原因推定を実現する。これにより、実運転下においても制御パラメータの最適化を迅速かつ実用的に行えるシステムの構築を目指す。

## 6. まとめ

本研究では、数値統計解析、画像診断、機械学習の3手法を用いて、ビーム異常の検出および制御パラメータの最適化を試みた。ここで「異常」とは、通常よりビームロスが顕著に多いイベントとして定義した。いずれの手法もインプットもモデルも試行錯誤の初期段階ではあるが、有望な結果が得られた。特に、CAE (Convolutional Autoencoder) を用いた画像診断においては、視覚的特徴に基づいた異常検知の有効性が示唆された。

明らかに異常と判別できる事象については、既存の

MPS により既に検出可能であるが、機械学習の導入により、MPS では判断困難なビームロスの原因推定や、装置の潜在的な故障兆候の早期発見が可能となること期待される。一方、IBFB に関する制御パラメータの最適化には、現時点では十分な統計が得られておらず、さらなるデータ蓄積が必要である。今後は、より多くの運転データの蓄積と学習モデルの改良を進めることで、加速器運転への実用的な応用を目指す。

また、ビームに関する非線形性（非線形光学効果や空間電荷効果など）については、従来の多粒子シミュレーションによってフィードバック・システムを含む性能評価が可能であり、定量的な解析手法として重要である。一方で、本研究で導入する機械学習ベースの手法においても、これらの非線形性を含めた複雑な挙動をデータから統合的に捉えることが期待される。したがって、従来の物理モデルに基づくアプローチと本手法は相補的な関係にあり、両者を併用することで、より実用的かつ汎用性の高い最適化・診断技術の構築につながると考えられる。

## 謝辞

EPICS のレコード取得ライブラリを提供していただいた山本昇氏、EPICS レコードの不明点を教えていただいた山田秀衛氏、IBFB のレコードについて教えていただいた岡田雅之氏、打ち合わせで議論した MR モニターグループの皆様へ感謝します。

## 参考文献

- [1] T. Toyama *et al.*, Proceedings of the 12th Annual Meeting of Particle Accelerator Society of Japan, Tsuruga, Japan, Aug. 5–7, pp. 722–724.
- [2] <https://pytorch.org/>
- [3] <https://epics-controls.org/>
- [4] N. Yamamoto, EPICS library internal tool.
- [5] M. Arinaga *et al.*, *Nucl. Instr. Meth.*, vol. 499, pp. 100–137, 2003.
- [6] S. Hiramatsu, KEK Internal 2004-4.
- [7] T. Kimura and K. Sato, “OPERATION STATUS OF J-PARC MR MACHINE PROTECTION SYSTEM AND FUTURE PLAN”, in *Proc. ICALEPCS'17*, Barcelona, Spain, 2017.
- [8] K. Satou and T. Toyama, “UPGRADE PLAN OF BLM SYSTEM OF J-PARC MR”, in *Proc. IPAC'12*, New Orleans, Louisiana, USA, 2012.
- [9] G. E. Hinton and R. R. Salakhutdinov, “Reducing the Dimensionality of Data with Neural Networks”, *Science*, vol. 313, no. 5786, pp. 504–507, 2006.
- [10] J. Masci *et al.*, “Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction”, in *Proceedings of the International Conference on Artificial Neural Networks (ICANN)*, pp. 52–59, 2011.
- [11] <https://www.dimtel.com/>
- [12] T. Baltrušaitis *et al.*, “Multimodal Machine Learning: A Survey and Taxonomy”, *Computer Vision and Image Understanding*, vol. 171, pp. 2–40, 2018.