

画像認識技術により、マウンテンプロット画像から運動量広がりと縦方向の ビーム形状を求める

IMAGE RECOGNITION TECHNOLOGY IS USED TO OBTAIN MOMENTUM DISTRIBUTION AND LONGITUDINAL BEAM SHAPE FROM MOUNTAIN PLOT IMAGE

野村昌弘^{*,A)}、沖田英史^{A)}、島田太平^{A)}、田村文彦^{A)}、山本昌亘^{A)}、
杉山泰之^{B)}、長谷川豪志^{B)}、原圭吾^{B)}、大森千広^{B)}、吉井正人^{B)}

Masahiro Nomura^{*,A)}, Hidefumi Okita^{A)}, Taihei Shimada^{A)}, Fumihiko Tamura^{A)}, Masanobu Yamamoto^{A)},
Yasuyuki Sugiyama^{B)}, Katsushi Hasegawa^{B)}, Keigo Hara^{B)}, Chihiro Ohmori^{B)}, Masahito Yoshii^{B)}

^{A)}Japan Atomic Energy Agency, JAEA

^{B)}High Energy Accelerator Research Organization, KEK

Abstract

At the J-PARC, image recognition technology based on Convolutional Neural Networks (CNN) is applied to images called mountain plots to obtain information on the incident beam from the linac. Currently, the momentum spread of the incident beam is obtained as the standard deviation of the Gaussian distribution, and the longitudinal beam shape is obtained as the time width of the beam with constant intensity. However, it is desired that the information about them be obtained not as values but as a distribution on phase space. In this study, we tried to obtain the distribution on phase space from the images of mountain plots by using image recognition techniques. As a result, in order to correctly reproduce the distribution on phase space, it was necessary to consider what kind of distribution it is, and to prepare learning images that can represent the distribution. By training those learning images with CNN, the distribution on phase space can be reproduced as a predictive image.

1. はじめに

J-PARC RCS では、畳み込みニューラルネットワーク (Convolutional Neural Network:CNN) による画像認識技術により、マウンテンプロットの画像から RCS への入射調整時に必要な運動量やタイミングのオフセット等の情報が得られるようにしている [1]。

現状では、得られている情報の中で、入射ビームの運動量広がりについてはガウス分布の標準偏差として、また縦方向のビーム形状については強度が一定としてその時間幅として求められている。しかし、これらの情報に関してはそれぞれの値としてではなく、運動量広がりや時間とで表される位相空間上での分布として求められることが望まれる。

そこで本研究では、ニューラルネットワークの出力を値から画像に変更し、位相空間上での分布の画像を学習させることにより、マウンテンプロットの画像から位相空間上での分布をニューラルネットワークの予測画像として求められる様にした。

2. 使用したニューラルネットワーク

今回、画像認識に使用した CNN は、オートエンコーダを参考に、機械学習用のライブラリー TensorFlow を用いて作成した。使用した計算機は主に、Apple M1 Max 搭載の Mac Studio である。使用した CNN の構成を Fig. 1 に示す。今回使用した CNN は全部で 18 層で、前半 13 層が畳み込み部分にあたる。入力である 400x120 の大きさのマウンテンプロットの

画像は、CNN のパラメータ数を減らす為に、情報を含んでいる中央部分の 400x50 の画像のみを CNN の畳み込み層への入力画像とした。前半の畳み込み部分で得られた情報は、15 層目に特徴量として、1x625 の値として抽出され、その後の 3 層の画像生成部分により 25x25 の予測画像として生成される。




Figure 1: Configuration of the CNN.

3. 単純な分布による検証

この節では、先ず今まで行ってきた、運動量広がりや縦方向のビーム形状が、標準偏差 σ と時間幅 W の二つのパラメータで記述される分布が、今回の CNN により予測画像として再現されるかを検証してみる。

パラメータの範囲は、RCS への入射調整時のビーム条件を考慮し設定した。このパラメータの設定範囲が学習する領域に対応している。入射はマルチターン入射で行われ、入射ターン数は 30 ターンである。設定したパラメータを以下に示す。今回は、位相空間上での分布のみを求めているので、運動量とタイミングのオフセットの値はある意味一種の外乱となっている。

* masahiro.nomura@j-parc.jp

- 運動量広がり $\sigma = 0.07 \sim 0.13$ [%]
- 時間幅 $W = 70 \sim 110$ [nsec]
- 運動量オフセット = $-0.1 \sim +0.1$ [%]
- タイミングオフセット = $-10 \sim +10$ [nsec]

今回、学習用画像や検証用画像は全てシミュレーションで作成した。シミュレーションでは、先ず設定範囲内で乱数により決められた運動量広がり σ と時間幅 W とで記述される位相空間上での分布が作成され、次に入射毎にその分布に従って作られた粒子を初期条件としてシンクロトロン振動を表す運動方程式に従ってマウンテンプロットの画像は作成される。作成したマウンテンプロットの画像 (入力画像) と位相空間上での分布 (正解にあたる教師画像) のいくつかの例を Fig. 2 に示す。学習用画像として 4500 枚、検証用画像として 500 枚を作成した。




Figure 2: Examples of images of mountain plots and distributions on phase space.

作成した学習用画像を学習した CNN により、検証用画像に対して得られた予測画像の例を Fig. 3 に示す。Figure 3 には、時間軸方向と運動量方向に積分した、運動量広がりや時間幅も載せている。赤線は正解である教師データ、薄青色部分は予測画像から得られた結果を表している。予測画像は教師画像を良く再現しており、学習した CNN を用いることにより、以前と同様に、ガウス分布の標準偏差 σ や時間幅 W が求められることが確かめられた。

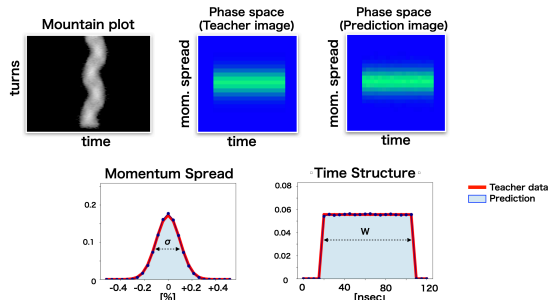


Figure 3: Prediction results from the trained CNN.

4. 学習していない分布の予測

前節では、単純な位相空間上での分布を学習し、学習した分布と同様の分布は、予測画像として再現できることが確かめられた。しかし、これですべての位相空間上での分布を再現できる訳ではない。当然ではあるが、学習していない分布は正しく再現す

ることはできない。例として、入射ビームが立ち上がり、立ち下がりに傾きを持った場合の予測結果を Fig. 4 に示す。運動量広がりや再現できているが、時間構造は再現できていない。予測画像は学習した分布形状、立ち上り立ち下がりがシャープのままである。予測結果は、立ち上がり立ち下がりがシャープなモデルで近似した結果となっている。

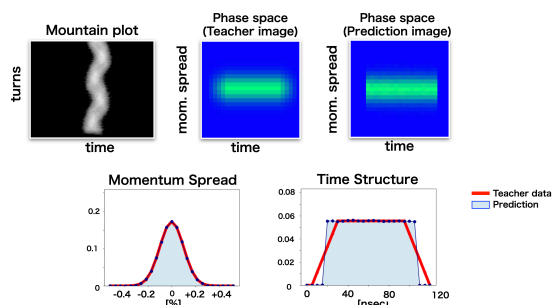


Figure 4: Prediction results from the trained CNN.

ここまでの結果から、位相空間上での分布を正しく再現するためには、その分布を表すことのできる学習用画像を準備することが必要であることが分かる。

5. 位相空間上での分布

この節では、現実的な位相空間上での分布を予測してみる。その為には、前節の結果が示す様に、現実的な位相空間上での分布を表すことのできる学習用画像を準備する必要がある。現実的な位相空間上での分布を考えた場合には、時間構造としては、立ち上がりや立ち下がりはある程度の傾きを持っていて、運動量広がりに関しては、テールを引く場合もある。さらに、立ち上がり、フラット部、立ち下がりで、運動量広がりやが異なる可能性もある。そこで、以上を表現できるように、時間構造、運動量広がりやを Fig. 5 に示す様にして作成した。




Figure 5: Setting conditions for time structure and momentum spread.

時間構造に関しては、上辺の長さを底辺の 0.2~1.0 倍とし、底辺に対する位置を変えることにより、立ち上がりや立ち下がりが垂直から傾きを持った場合でも対応できるようにした。また、運動量広がりに関しては、標準偏差 σ_1 で表されるガウス分布 1 に σ_1 の 1.0~2.0 倍の標準偏差 σ_2 を持つガウス分布 2 を加えることにより、テールを引いた分布にも対応できるようにした。更に、立ち上がり立ち下がり部

分での運動量広がり、中央のフラット部に対して、その広がりを0.6~1.4倍とすることにより、運動量広がりへの違いにも対応できる様にした。

この条件に従って作成された教師画像となる位相空間上での分布とそれにより作成された入力画像であるマウンテンプロットの画像のいくつかの例をFig. 6に示す。学習用画像として45000枚、検証用画像として5000枚を作成した。




Figure 6: Examples of images of mountain plots and distributions on phase space.

この45000枚を学習したCNNにより、検証用画像を用いて位相空間上での分布の予測を行った。予測画像が正しく再現できているかが確かめられる様に、検証には、立ち上がり立ち下がりに傾きを持ち、それぞれで運動量広がり違う検証用画像を使用した。得られた結果をFig. 7に示す。

Figure 7を見ると位相空間上での分布を表す予測画像は、教師画像と比較すると少しぼやけているが、時間構造は、教師データを良く再現している。また、立ち上がり、フラット、立ち下がり部分それぞれで時間方向に積分して求めた運動量広がり、教師データをそれぞれ再現していることが分かる。

この様に、この程度の複雑な位相空間上の分布でも、その分布を表すことのできる学習用画像を準備すれば、位相空間上での分布を予測画像として再現できることが確かめられた。

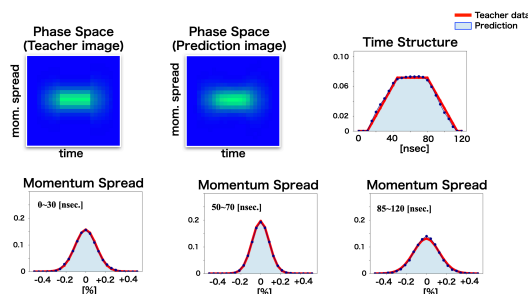


Figure 7: Prediction results from the trained CNN.

6. 画像認識技術の有効性

この節では、CNNによる画像認識がどこまで細かく画像を認識しているかを調べてみる。Figure 8に、立ち上がり立ち下がりが垂直な場合と傾きを持った場合のマウンテンプロットの画像と位相空間上での分布を示す。立ち上がり立ち下がり以外の条件は全く同じにしている。マウンテンプロットの画像を見た

限りでは両者の違いはわずかで、人ではこの画像から立ち上りや立ち下りを判断することは難しい。




Figure 8: Images of the mountain plots and the distributions on phase space.

Figure 9に、前節で位相空間上での分布を再現したCNNによる予測結果を示す。Figure 8のマウンテンプロットの画像の違いはわずかではあるが、Fig. 9の予測画像では、運動量広がり、両結果とも同じ教師データを再現しており、時間構造に関しては、立ち上りと立ち下りの違いがしっかりと表れ、それぞれが教師データを再現している。このことから、CNNによる画像認識技術が細かな点まで入力画像を認識していると考えられる。

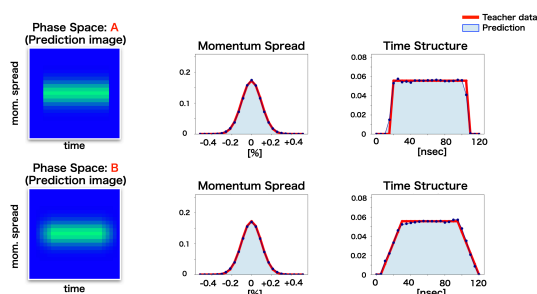


Figure 9: Prediction results from the trained CNN.

7. まとめ

CNNによる画像認識技術を利用し、マウンテンプロット画像から入射ビームの情報を位相空間上での分布として求めてみた。その結果、位相空間上での分布を正しく再現するためには、どのような分布なのかを考察し、その分布を表すことができる学習用画像を準備することが必要であった。そして、適切な学習用画像を準備し、CNNに学習させることにより、対応する位相空間上での分布を再現することができた。さらに、CNNによる画像認識技術では、画像全体を細部まで認識していると考えられる。

参考文献

- [1] M. Nomura *et al.*, Proceedings of 17th Annual Meeting of Particle Accelerator Society of Japan (2020) 64.