

深層生成モデルのマウンテンプロット画像への適用 APPLYING A DEEP GENERATIVE MODEL TO MOUNTAIN PLOT IMAGES

野村 昌弘 ^{*,A)}, 島田 太平 ^{A)}, 田村 文彦 ^{A)}, 沖田 英史 ^{A)}, 宮越 亮輔 ^{A)},
清矢 紀世美 ^{B)}, 吉井 正人 ^{B)}, 大森 千広 ^{B)}, 原 圭吾 ^{B)}, 長谷川 豪志 ^{B)}, 杉山 泰之 ^{B)}
Masahiro Nomura ^{*,A)}, Taihei Shimada ^{A)}, Fumihiko Tamura ^{A)}, Hidefumi Okita ^{A)}, Ryosuke Miyakoshi ^{A)},
Kiyomi Seiya ^{B)}, Masahito Yoshii ^{B)}, Chihiro Ohmori ^{B)}, Keigo Hara ^{B)}, Katsushi Hasegawa ^{B)}, Yasuyuki Sugiyama ^{B)}
^{A)} JAEA J-PARC, ^{B)} KEK J-PARC

Abstract

In the J-PARC RCS, information about the injection beam from the Linac, which is necessary for adjustments, is converted into an image called a mountain plot. This allows the offset of the injection beam's momentum and timing to be visualized. One of the recently popular deep generative models is the Conditional Variational Auto Encoder (CVAE). CVAE can generate different digits while preserving the original handwriting style by learning from numerous handwritten digits. In this study, leveraging the characteristics of the CVAE, we were able to generate a new image from the measured mountain plot. This new image maintained the same conditions such as momentum distribution and time width but altered the number of injection turn from 30 to 1. Furthermore, this paper explores the application of CVAE in the field of accelerator, based on the acquired findings. We proposed one method using the parameter sets of various accelerator components as inputs and labeling the beam state. This method should enable the generation of new parameter sets that reflect changes in the beam state, revealing which parameters influenced the beam state. We tested this approach in a simple scenario using mountain plots and were able to show its potential.

1. 序

J-PARC RCS では、ビーム調整に必要な Linac からの入射ビームに関する情報をマウンテンプロットと呼ばれる画像とすることにより、入射ビームの運動量や入射タイミングのオフセットが視覚的に分かる様になっている。調整時にはノイズの大きさを考慮し 30 ターン入射で行っている為、マウンテンプロットの画像は、周回しているパルスが重なり合った状態での画像となっている。この為、位相空間上での運動が分かりやすい様に、1 ターン入射でのマウンテンプロットの画像が望まれている。さらに、マウンテンプロットの画像は、先に述べた様にノイズの影響やタイミングジッタの影響も受けている。Figure 1 に調整後のマウンテンプロットの画像と wall current monitor の波形を示す。




Figure 1: Mountain plot and Waveform.

そこで今回、測定したマウンテンプロットの画像から、深層生成モデルの一つである CVAE(Conditional Variational AutoEncoder) [1] を用いて、1 ターン入射でノイズ等の影響を受けていないマウンテンプロットの画像の生成を試みた。

2. CVAE

CVAE(Conditional Variational Auto Encoder) は深層生成モデルの一つで、VAE(Variational Auto Encoder) から生まれたとも考えられる。そこで先ず、VAE について説明する。VAE は学習するデータ (画像など) に対して潜在変数 z を仮定し、入力画像 X から潜在変数 z を生成し、この潜在変数 z から元の入力画像 X を生成している。そのため構造的には、Encoder と Decoder の 2 つの neural network からなり、autoencoder の構造をしているが、もともとは Bayes 的な発想から生まれている。

VAE はそもそも事後分布を近似するための手法として考えられており、結果として autoencoder の構造をしているだけと考えられる。この事後分布を近似する手法として、VAE では近似分布にニューラルネットワークを導入している。その結果、真の事後分布が複雑な形状をしている場合でも、この近似事後分布で十分に真の事後分布が表現できるようになっている。この部分が autoencoder の構造での encoder 部分に該当する。一方、decoder 部分は潜在変数 z から画像 X を生成することから尤度に該当していると考えられることができる。つまり、入力画像 X に対して近似事後分布で潜在変数 z を作成し、その潜在変数 z から出力画像 X を生成している。

この VAE に対して、CVAE では encoder と decoder の入力に正解ラベルを付与している。VAE と CVAE のネットワーク構造を Fig. 2 に示す。このラベルを付加する事が重要で、mnist(Modified National Institute of Standards and Technology database, 機械学習によく用いられる手書き数字の画像データセット) を用いた例では、CVAE では入力した手書き数字に対して筆跡はそのまま、decoder に入力したラベルに対応した入力とは別の手書き数字も生成することができている [2]。今回この特性

* masahiro.nomura@j-parc.jp

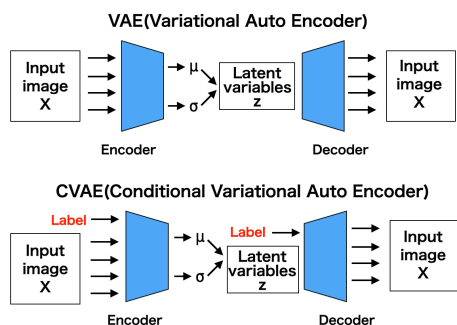


Figure 2: Network structure of VAE and CVAE.

に注目して、マウンテンプロットの画像に CVAE による画像生成を適用している。CVAE やその学習に関する目的関数は、参考文献 [3-5] を参照されたい。

3. マウンテンプロット画像への適用

マウンテンプロットの画像に CVAE を適用して画像生成を行うにあたり、手書き数字とマウンテンプロットは同種の構造を持つと考える。手書き数字とマウンテンプロットの画像を Fig. 3 に並べて示す。手書き数字の筆跡はマウンテンプロットの画像の線の太さやゆらぎに対応し、その数字は入射ターン数に対応していると考え、30 ターン入射の画像から入射ターン数以外の条件はそのまま、1 ターン入射のマウンテンプロットの画像が生成できるはずである。先に述べた CVAE の特性を利用した考え方である。




Figure 3: Mnist and mountain plot.

ここからは上で述べた考えに従って、マウンテンプロット画像に CVAE を適用し、画像生成を行なった。CVAE による学習から画像生成までの手順は、一般的な neural network における手順と同様に以下の手順で行なった。

- 学習用画像の準備
- 学習用画像を用いての学習
- 学習済 CVAE による画像生成

まずは学習用画像の準備について述べる。学習用画像として、シミュレーションにより作成したターン毎の波形に、測定データを参考にして、それと同様のノイズ(ガウス分布を仮定)とタイミングジッタを加えた画像を作成した。シミュレーションはシンクロトロン運動を記述する運動方程式により行った。測定画像とその波形、学習用画像とシミュレーションにより作成した波形とノイズを加えた波形の例を Fig. 4 に、作成し

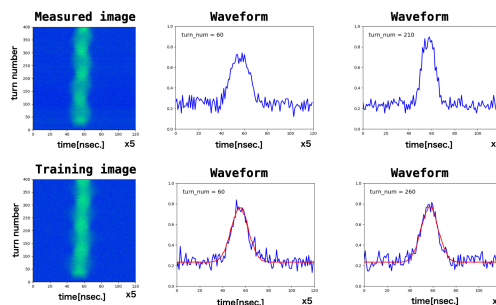


Figure 4: Measurement and training images and their waveforms. The red line shows simulation results.

た学習用画像の例を Fig. 5 に示す。学習用画像として 16000 画像、検証用画像として 4000 画像を準備した。




Figure 5: Examples of training images.

次に、準備した学習用画像を用いての学習について述べる。使用した CVAE の構造は参考文献 [2] を参考にし、画像の次元を mnist の 28x28 からマウンテンプロットの画像の次元 420x120 に変更した。潜在変数の次元 64 はそのまま使用した。プログラムは python で書かれており、機械学習用のライブラリとして keras を使用している。入力画像と正解ラベル、潜在変数に加える正解ラベルと CVAE の関係を Fig. 6 に示す。




Figure 6: Network structure of CVAE.

最後に画像生成について述べる。生成したい入射ターン数の画像は、入射ターン数の情報をラベルとして潜在変数と共に decoder に渡してやるだけで生成できる。そして、この生成された画像は、入射ターン数以外の条件は入力画像の条件そのままである。学習済 CVAE によりラベル毎に生成した画像とそれに対応した正解画像を Fig. 7 に示す。

正解画像は入射ターン数以外は同じ条件でシミュレートした画像で、ノイズに関しては平均している。学習では、出力画像を出来るだけ入力画像を再現するようにしているが、ノイズやタイミングジッタの部分は




Figure 7: Generated and ground truth images for each label.

再現することはできない。しかし、学習でその差を最小とする事により、ノイズやタイミングジッタの影響は平均化されると考えられる。Figure 7を見ると、確かに生成された各ラベルの画像は、ノイズやタイミングジッタの部分を平均化した正解画像を再現していることが分かる。このことは、実際の実験でも同じ測定を何度も繰り返す事により、ノイズ等が平均されることと同じと考えられる。

今回の目的は、30ターン入射から1ターン入射のマウンテンプロットの画像を生成することであったので、1ターン入射として生成されたマウンテンプロットのターン毎の波形と正解画像とを比較してみる。Figure 8に生成画像と正解画像から切り出したターン毎の波形を示す。波形毎の比較でも生成画像は正解画像を良く再現していることが分かる。




Figure 8: Waveforms from generated and ground truth images.

この様に CVAE による生成画像は正解画像を再現できるという結果を得たので、実際に測定したマウンテンプロット画像に適用し、1ターン入射の画像を生成した。結果を Fig. 9 に示す。生成画像は測定画像と比較して、入射したビームが時間方向にはほぼ均一で、運動量方向にはガウス分布であり、位相空間上で回転していることがはっきりと分かるようになっている。さらに、生成画像から求めた運動量分布と時間幅は測定時に設定した値をほぼ再現していた。

以上述べた様に、CVAE による画像生成からは良好な結果が得られた。そこで、ここではなぜ 30 ターン入射から 1 ターン入射の画像生成することができたかについて考えてみる。VAE では、入力画像を表す全ての情報を潜在変数として保持する。一方、CVAE ではその構造上、潜在変数から入射ターン数の情報を抜き出しラベルの情報とすることにより、ラベルの情報を変える事で、入射ターン数のみを変えた画像が生成できていると考えられる。この考え方を Fig. 10 に示す。つまり、潜在変数からラベルの情報を取り除くことが重要であり、潜在変数から変更したい情報を取り除いて、

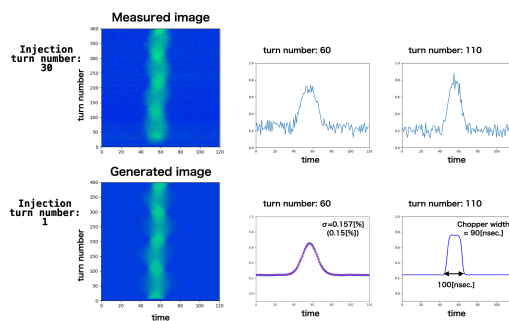


Figure 9: Measured and generated images and their waveforms.

ラベルとして新たな情報を与えることで、その情報に沿った画像が生成できている。




Figure 10: Network structure of CVAE. Information on labels is extracted from latent variables.

4. 加速器での CVAE の利用

今回 CVAE により画像生成を行なった結果、良好な結果が得られ、そのメカニズムについても理解する事ができた。そこでこの章では、これら得られた知識を基に、加速器での CVAE の利用について考えてみる。

ここまでは、ビームの状態を表す画像を入力として、機器のパラメータを変えた場合のビームの画像を生成してきた。ここでは発想を変えて、加速器の各機器のパラメータセットを入力とし、ビームの状態をラベルとすることにより、ビームの状態が変わった場合のパラメータセットが生成できるはずである。これら二つの考え方を Fig. 11 に示す。

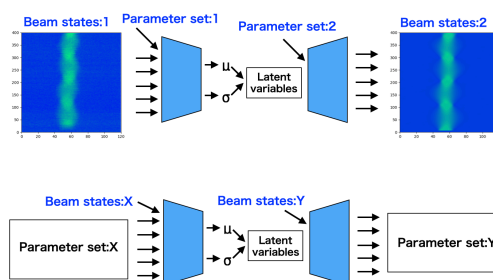


Figure 11: Network structure of CVAE. In the new approach, the parameter set of each equipment setting is used as input and the beam states is used as a label.

もしこれが可能ならば、例えば色々なパラメータセットを試した結果、ビームロスが低減した場合、ビームロ

スの大きさをラベルとし、ラベル毎のパラメータの変化をみると、影響を受けた機器のパラメータは変わり、影響を受けなかった機器のパラメータは変わらないはずである。その結果入力したパラメータの中で、どの機器がどれだけビームロスに影響を与えていたかが分かり、加速器のビーム調整に於いて有効な手段の一つとなり得る。

この可能性について、単純な場合ではあるがマウンテンプロットを用いて検証を行ってみた。検証を行う設定としては、ビーム調整中を模擬し、今のパラメータよりマウンテンプロットの振幅を小さくしたい。そこでどのパラメータが振幅に影響を与えているかが知りたいと言う設定とした。入力となるパラメータセットは、マウンテンプロットを作成する為に必要な入射タイミングと入射運動量、入射ビームの時間幅と運動量分布の4つのパラメータのセット。そして、この4つのパラメータの値を4箇所に入力した画像を学習用画像として準備した。パラメータセットに対応するラベルは、その4つのパラメータを用いて作成したマウンテンプロットの画像の振幅の大きさを4つに分類し、最小の振幅をラベル0、最大をラベル3とした。学習用画像として8000画像、検証用画像として2000画像を作成しCVAEに学習させた。パラメータセットとラベルによるCVAEの学習の様子をFig. 12に示す。Figure 12には、振幅の最大値を示すマウンテンプロットの画像も載せている。




Figure 12: Network structure of CVAE. The figure also includes an image of a mountain plot showing the maximum amplitude.

検証の為に、振幅が大きいマウンテンプロットとなるパラメータセットを2種類準備し、それらのパラメータセットの値を挿入した画像をテスト画像とした。その後、これら2つのテスト画像を入力としてそれぞれ振幅の違う4種類(ラベル0から3まで)のパラメータセットの画像を学習済みCVAEにより生成した。そして、それらの画像から各パラメータの変化を求めた。結果をFig. 13に示す。Figure 13には、画像生成の元となる入力としたパラメータセットによるマウンテンプロットの画像も載せている。パラメータセットの変化を表す図の縦軸は設定値からのオフセットを表し、入射タイミングと入射運動量の値が0の場合は振幅は0となる。

Figure 13の左のパラメータセット1では、入射運動量の変化が大きいことが分かる。このパラメータセット1で入力としたパラメータセットで作られたマウンテンプロットの画像を見ると、確かに振幅を大きくしているのが入射運動量であることが分かる。また、右のパラメータセット2では、入力としたパラメータセッ

トで作られたマウンテンプロットの画像を見ると入射




Figure 13: Variation of parameters per label generated using CVAE. The figure also includes images of mountain plots produced with the parameters of labels 3 and 0.

運動量に加えて入射タイミングが原因で振幅が大きくなっている事が分かる。パラメータセット2のラベル毎のパラメータの変化を見てみると、確かに、ラベルの変化に対して入射運動量に加えて入射タイミングの変化も大きく、これらが振幅を大きくしている要因である事が分かる。時間幅と運動量分布に関しては、パラメータセット1と2の両方でほとんど変化が無く、振幅には影響を与えていないパラメータであることが分かる。

この様に、CVAEによりマウンテンプロットの振幅が違うパラメータセットを生成することができ、どのパラメータが振幅に影響を与えていたかが分かるようになった。非常に単純な場合ではあるが、これらの結果からこういった使い方での可能性を示す事ができたと考えている。

5. まとめ

CVAEを使ってみた感想になるが、生成モデルであるCVAEには可能性を感じるが、まだ始めたばかり。潜在変数からどのような情報を抜き出しどのような情報を加えることができるのか、入力画像(情報)に対してどのようなCVAEの構造が適切か、生成された画像(情報)の確かさはどうか等更なる検証が必要と思われる。また重要な事として、基本的には教師無し学習なので、実際のデータを使用して行うのが可能であり、理想である。これには十分なデータが得られるかが鍵である。

参考文献

- [1] Kingma, D. P., Mohamed, S., Jimenez Rezende, D., & Welling, M., Semi-supervised Learning with Deep Generative Models, in Advances in Neural Information Processing Systems 27 (2014), pp. 3581-3589.
- [2] Conditional Variational Autoencoder (CVAE) を TensorFlow 2 系で実装する, <https://qiita.com/kn1cht/items/ebd392aaa8f1741a00c2>
- [3] 深層生成モデルを巡る旅 (2): VAE, <https://qiita.com/shionhonda/items/e2cf9fe93ae1034dd771>
- [4] Variational Autoencoder(VAE) を学ぼう (1/2), <https://blog.deepblue-ts.co.jp/image-generation/variational-autoencoder-part1/>
- [5] Variational Autoencoder(VAE) を学ぼう (2/2), <https://blog.deepblue-ts.co.jp/image-generation/variational-autoencoder-part2/>