

THOT02

J-PARC

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

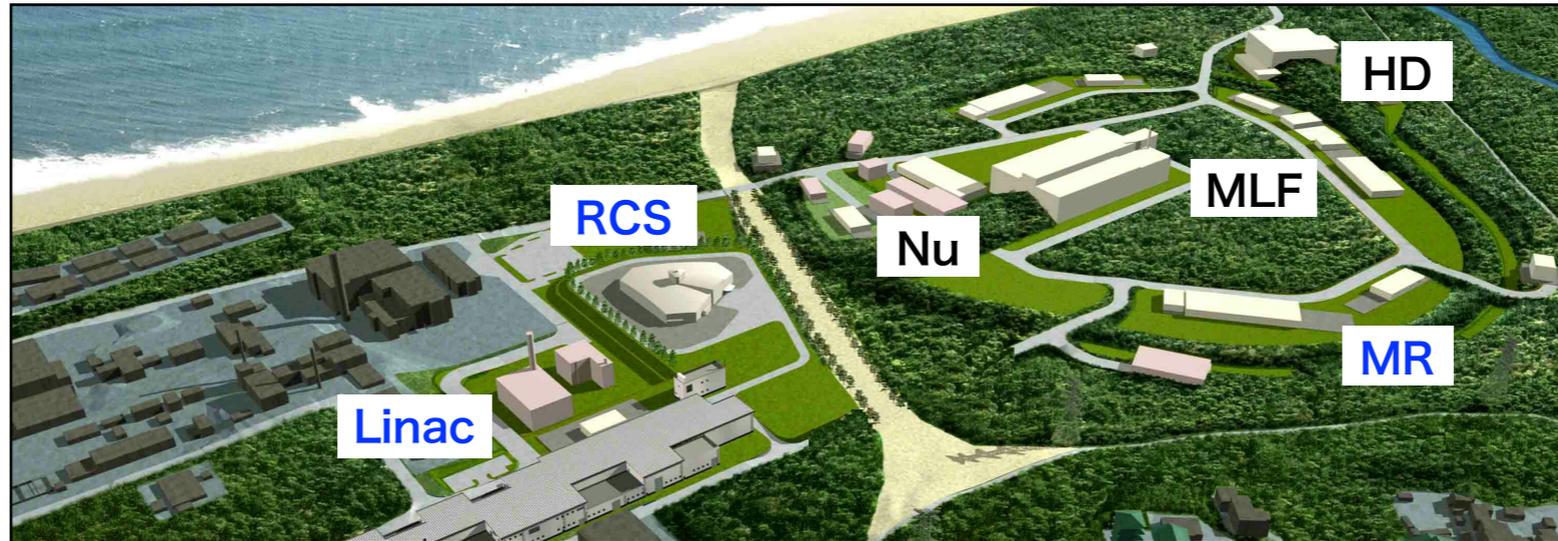
○ 野村 昌弘, 島田 太平, 田村 文彦, 沖田英史, 宮越 亮輔
(日本原子力研究開発機構 J-PARC)

清矢 紀世美, 吉井 正人, 大森 千広, 原 圭吾, 長谷川 豪志, 杉山 泰之
(高エネルギー加速器研究機構 J-PARC)

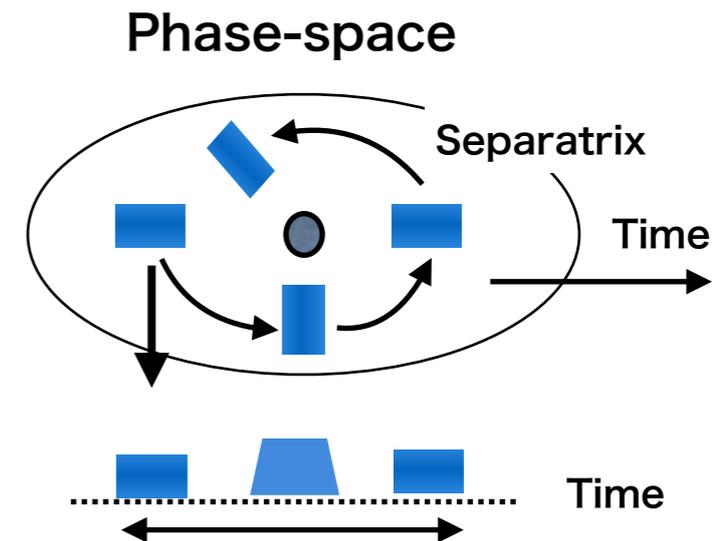
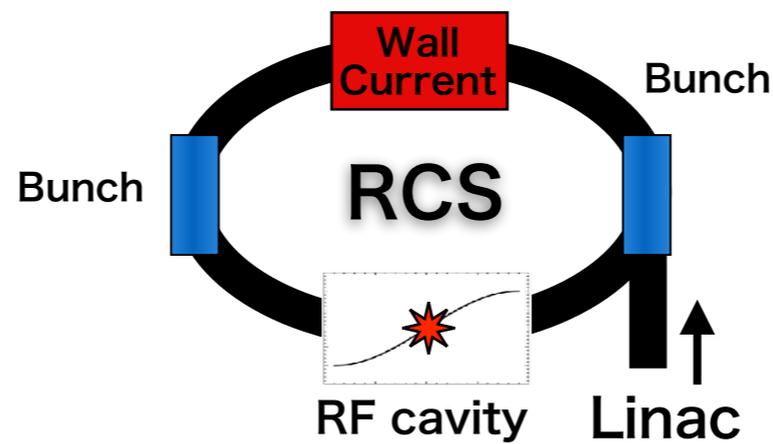
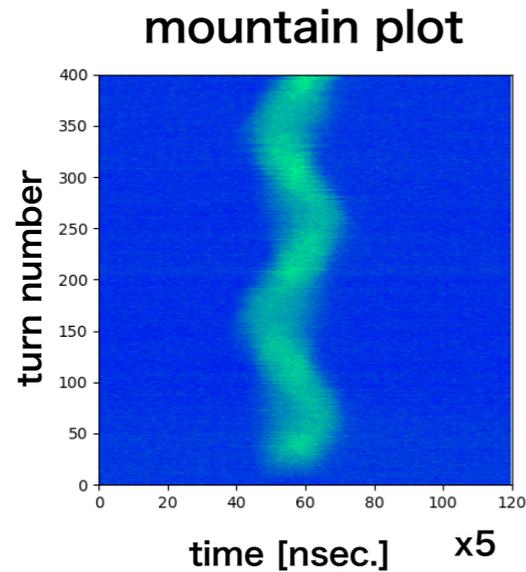
第21回日本加速器学会年会

mountain plotとは

J-PARC 鳥瞰図

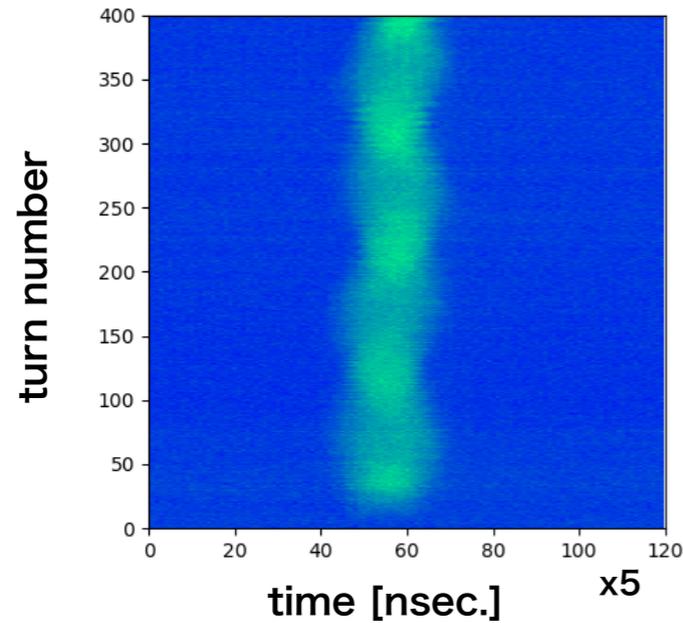


Wall current monitorで測定し、
入射ビームの縦方向の振動を視覚的に分かる様にした画像。
RCS、MRへの入射ビームの調整に使用している。



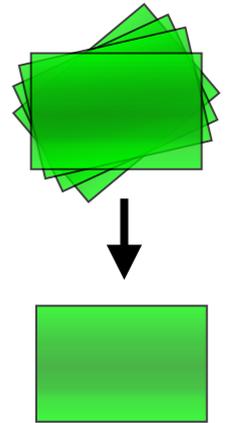
今回何をやったかとその動機

mountain plot

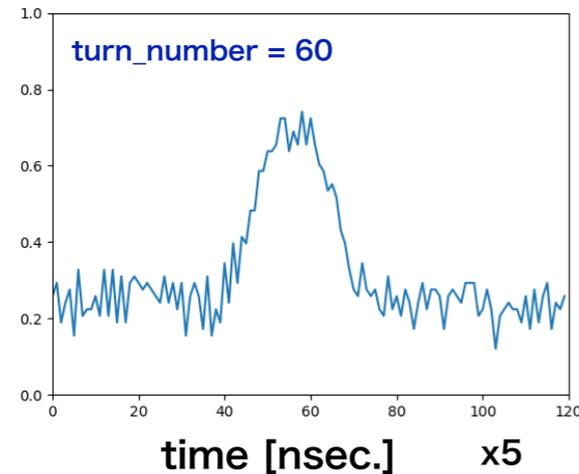


入射ビームの調整では、
ノイズとの関係で30ターン入射で行なわれている為、
周回しているパルスと重なりあった画像となっている。

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としたい。



waveform



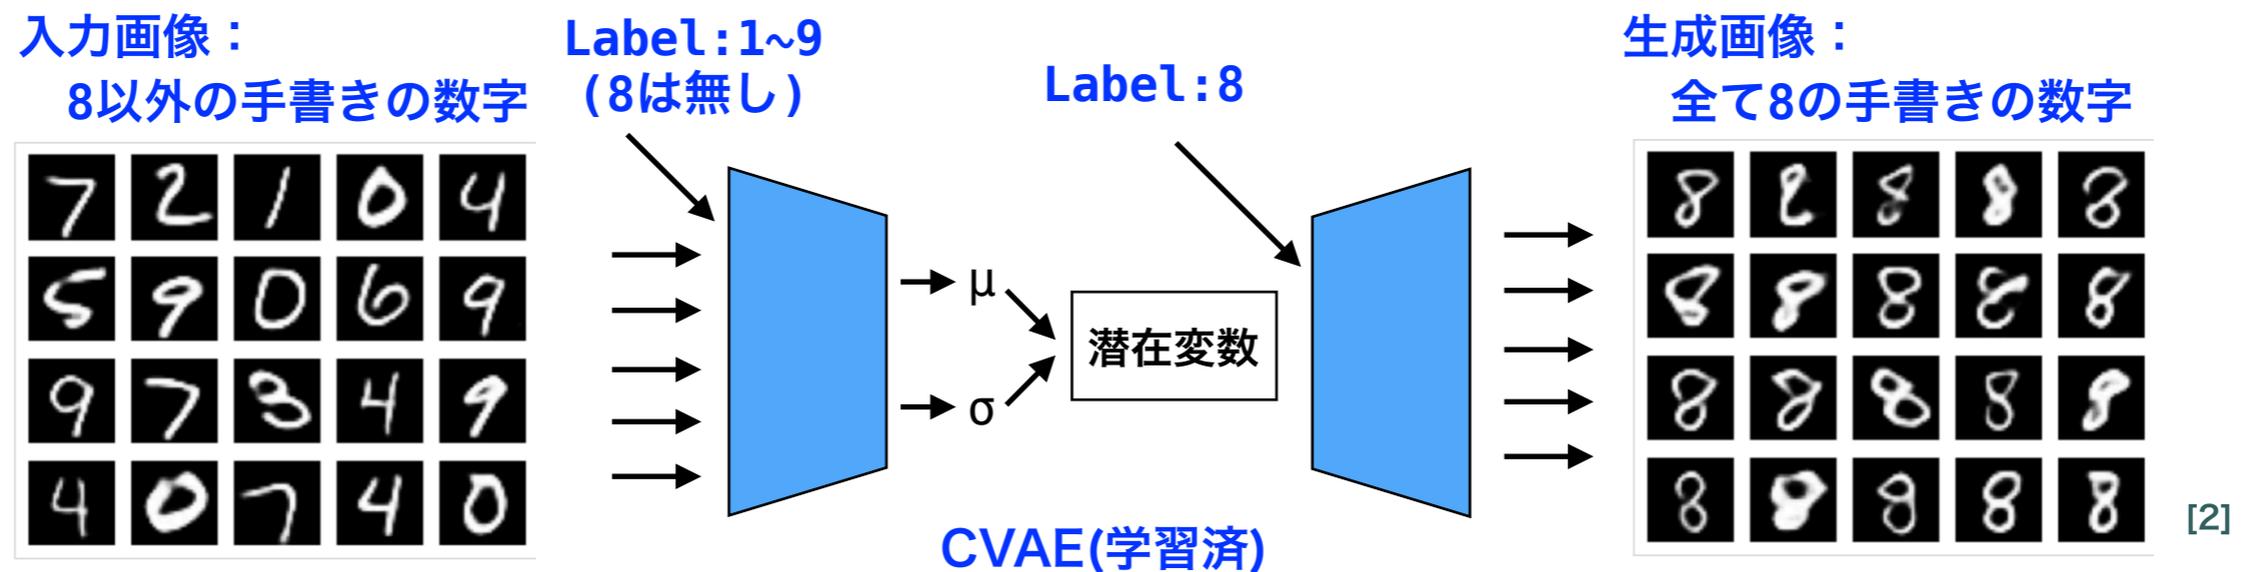
さらに、ノイズやタイミングジッターの影響を排除したい。

測定した30ターン入射の画像から、
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を生成してみる。

CVAE(Conditional Variational Auto Encoder) [1]

CVAE：深層生成モデルの一つ。

CVAEでは、筆跡はそのままで別の数字を生成することができる。

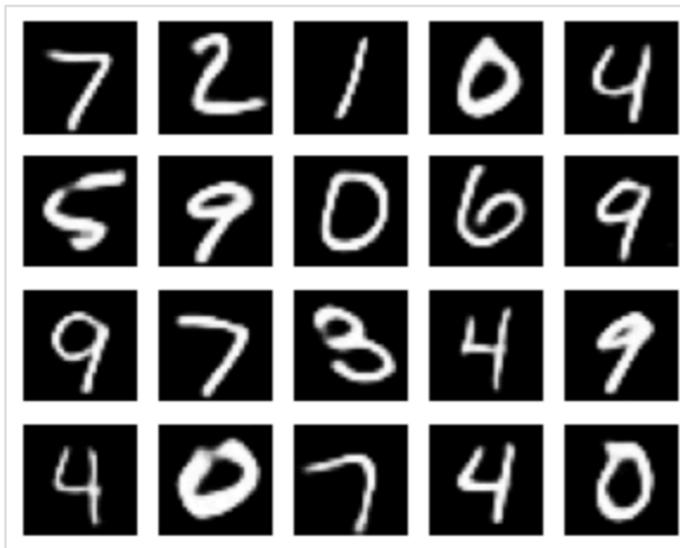


[1] Kingma, D. P., Mohamed, S., Jimenez Rezende, D., & Welling, M. (2014). Semi-supervised Learning with Deep Generative Models. In Advances in Neural Information Processing Systems 27 (pp. 3581-3589).

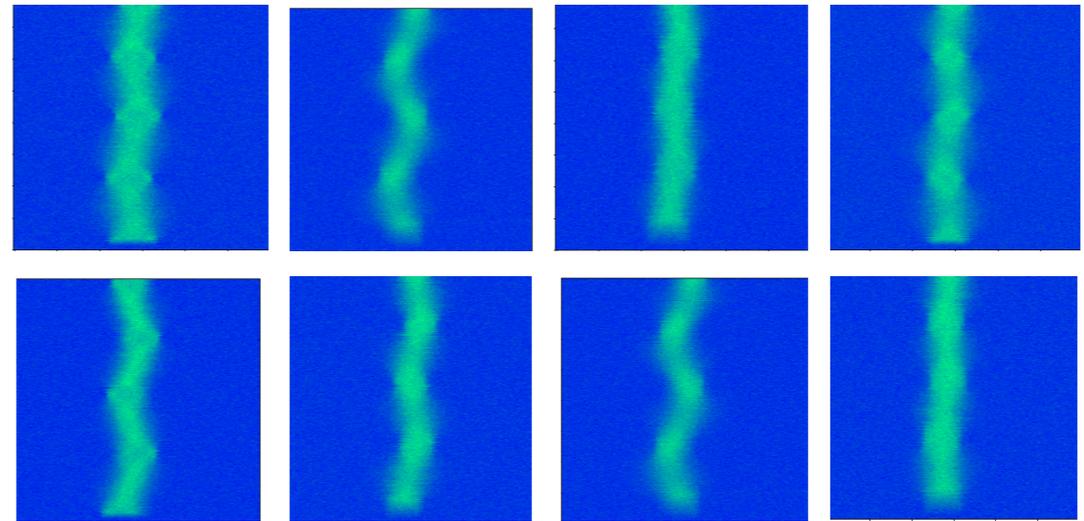
[2] <https://qiita.com/kn1cht/items/ebd392aaa8f1741a00c2>

手書き数字とmountain plot

手書き数字



mountain plot

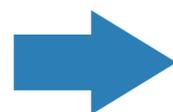


CVAEでは、筆跡はそのままで別の数字を生成することができる。

筆跡 -> マウンテンプロットの線の太さやゆらぎ

数字 -> 入射ターン数

CVAEが認識してくれれば



入射ターン数以外の情報はそのまま、

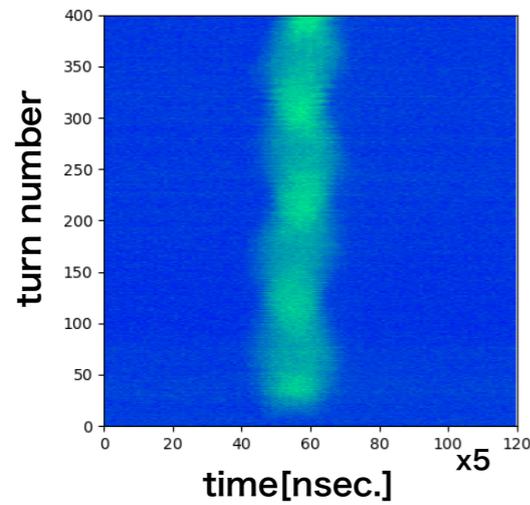
30ターン入射の画像から1ターン入射の画像が生成できるはず

CVAEを mountain plot へ適用

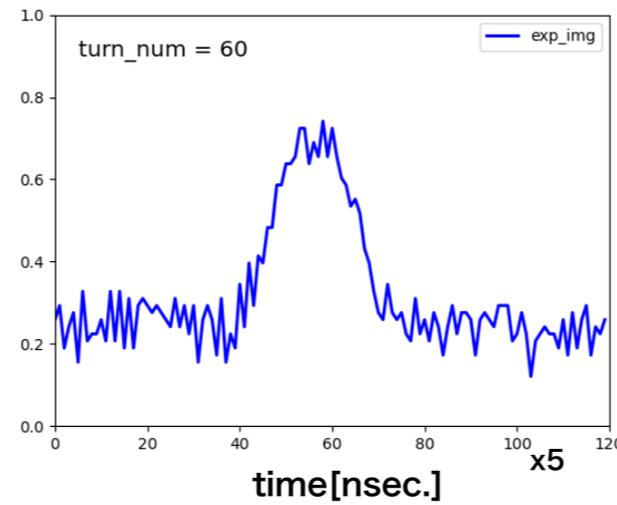
まずは、学習用画像の準備

画像はシミュレーションで作成
(シンクロトン運動を記述)

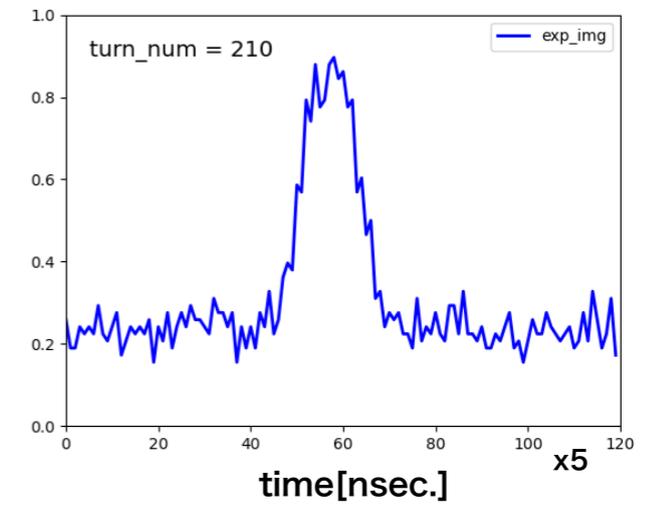
測定画像



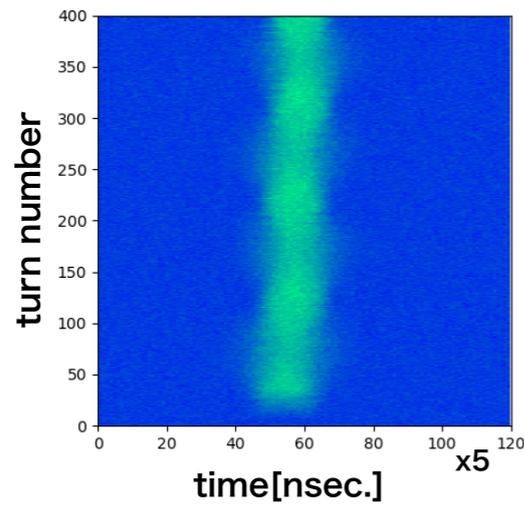
waveform



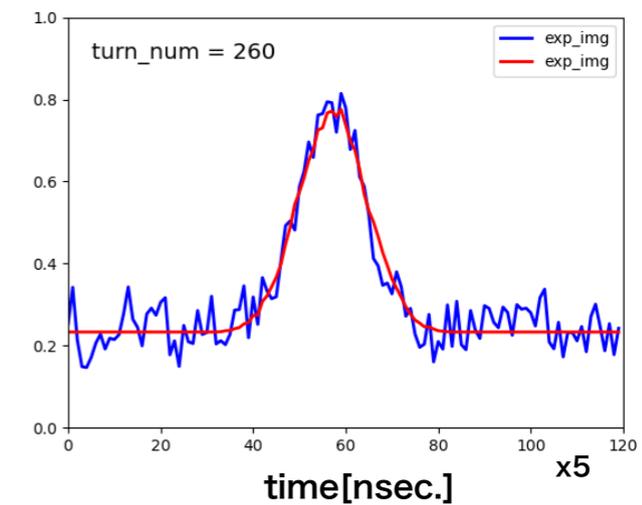
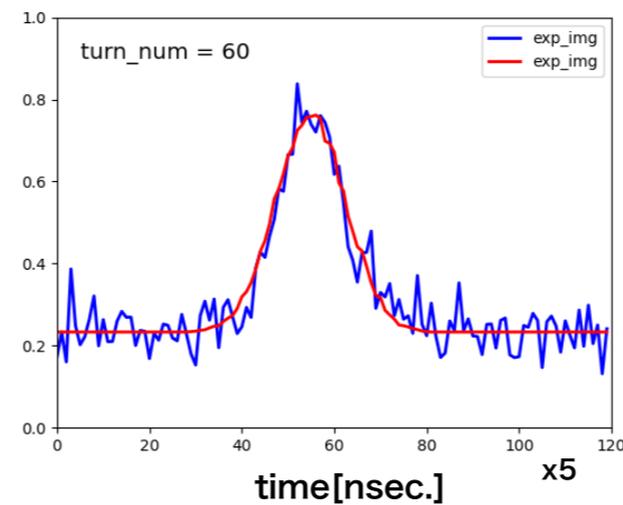
waveform



学習用画像

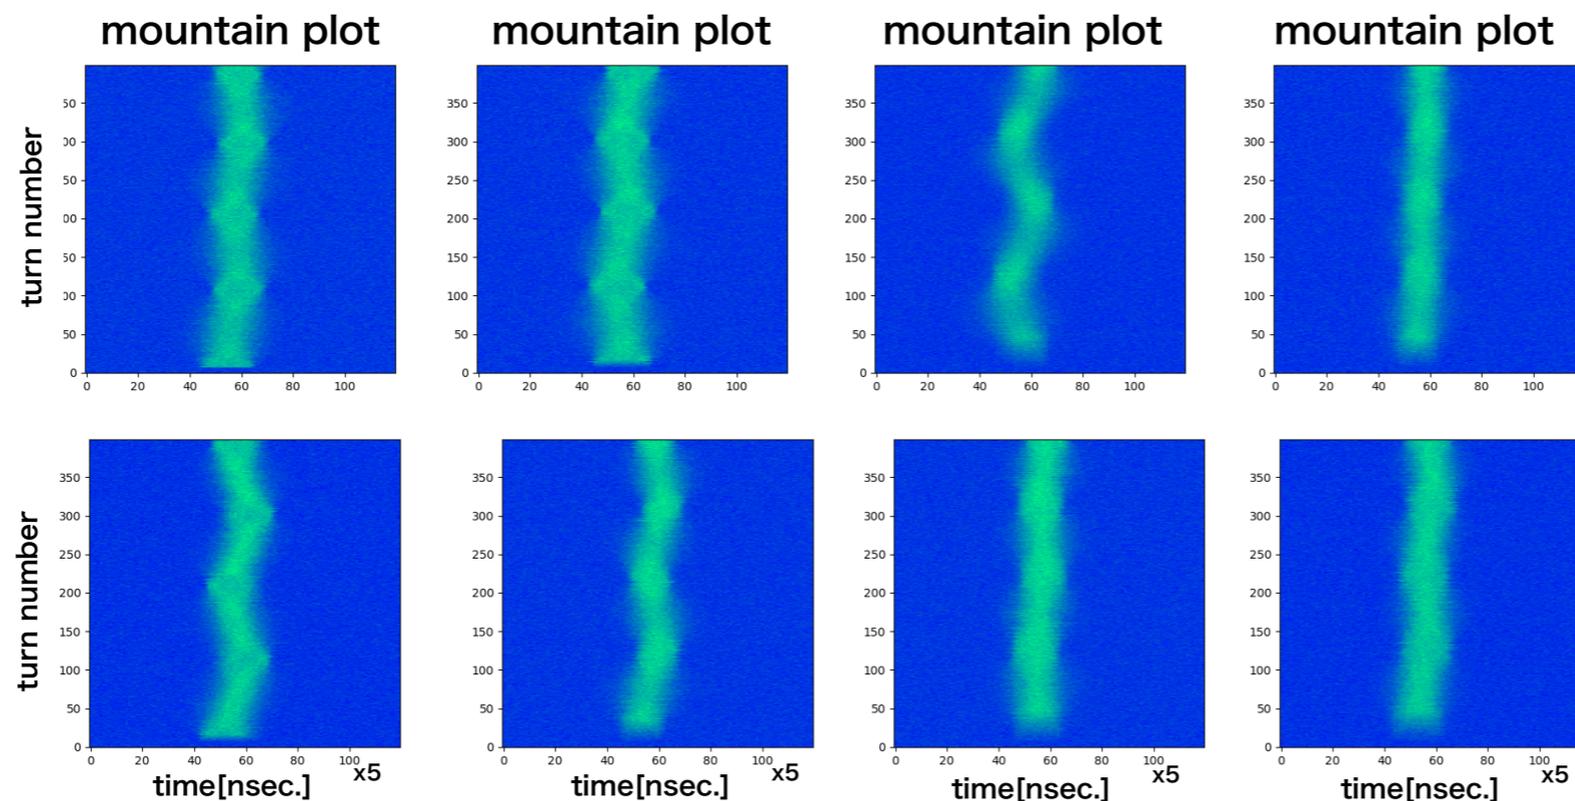


シミュレーションにノイズとタイミングジッタを加えて作成



準備した画像とラベル

画像：



パラメータ

入射タイミングと運動量
入射ビームの時間幅と運動量分布

+

入射ターン数(1,10,20,30,40)

学習用画像：16000枚

検証用画像：4000枚

ラベル：入射ターン数、手書きの0~9の数字10個に対して、5個を設定。

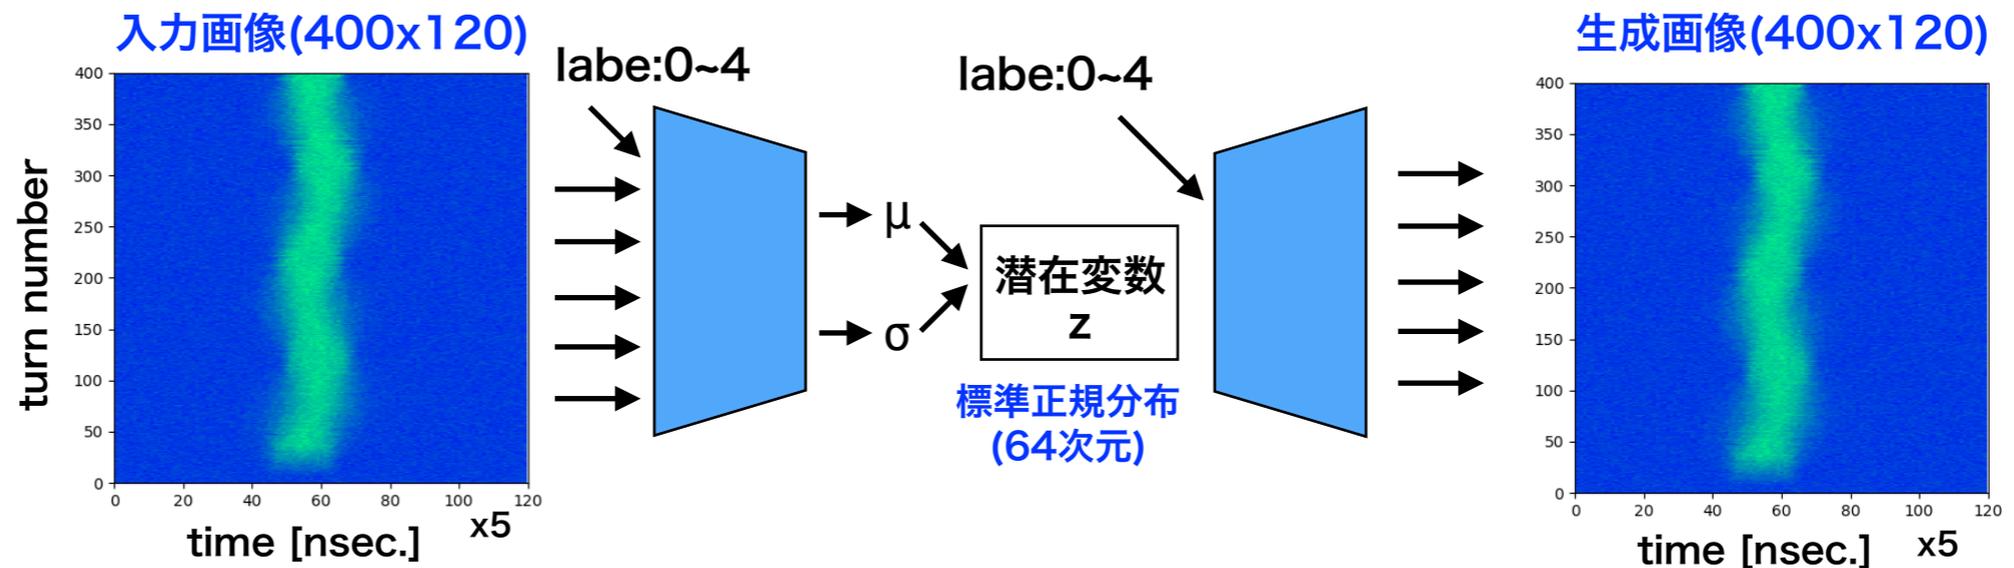
Label:0 -> 30turn Label:3 -> 20turn

Label:1 -> 1turn Label:4 -> 40turn

Label:2 -> 10turn

CVAE による学習 [2]

使用したCVAEは、参考文献[2]を参考にして画像の次元を変更したものの。



学習では、潜在変数 z が標準正規分布に、生成画像が入力画像となる様にCVAEのパラメータを決定。

[3-5]

画像にはノイズ等が含まれているが、

入力画像と生成画像との差を最小にすることにより、その影響は平均化されるはず。

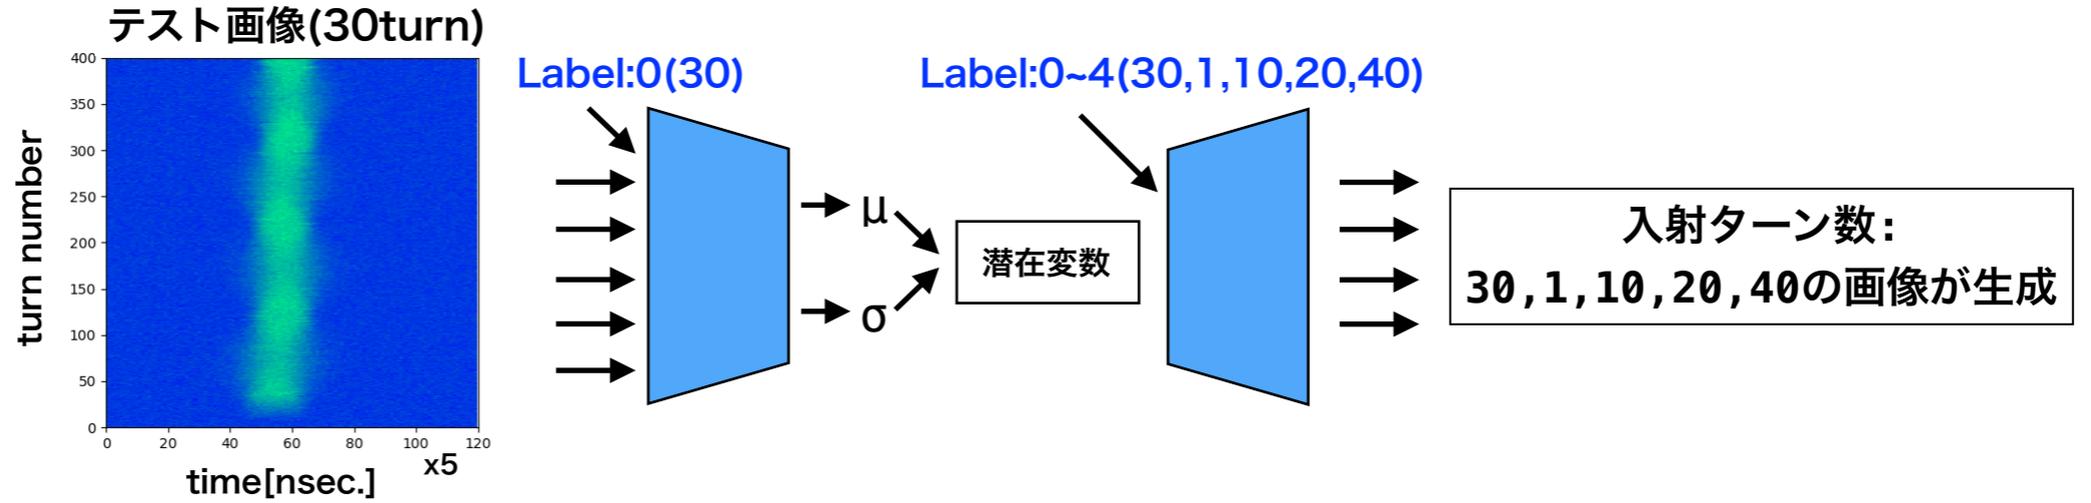
[2] <https://qiita.com/kn1cht/items/ebd392aaa8f1741a00c2>

[3] <https://qiita.com/shionhonda/items/e2cf9fe93ae1034dd771>

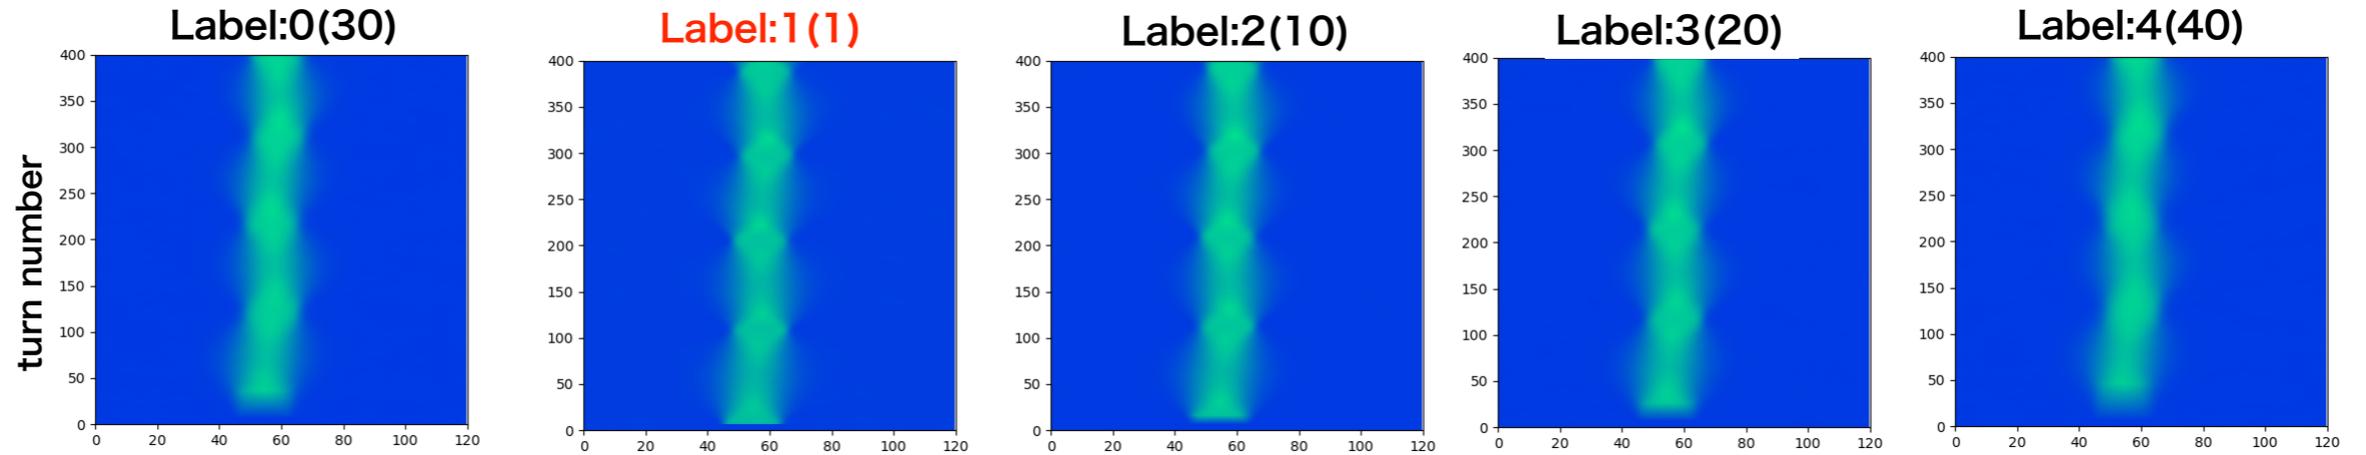
[4] <https://blog.deepblue-ts.co.jp/image-generation/variational-autoencoder-part1/>

[5] <https://blog.deepblue-ts.co.jp/image-generation/variational-autoencoder-part2/>

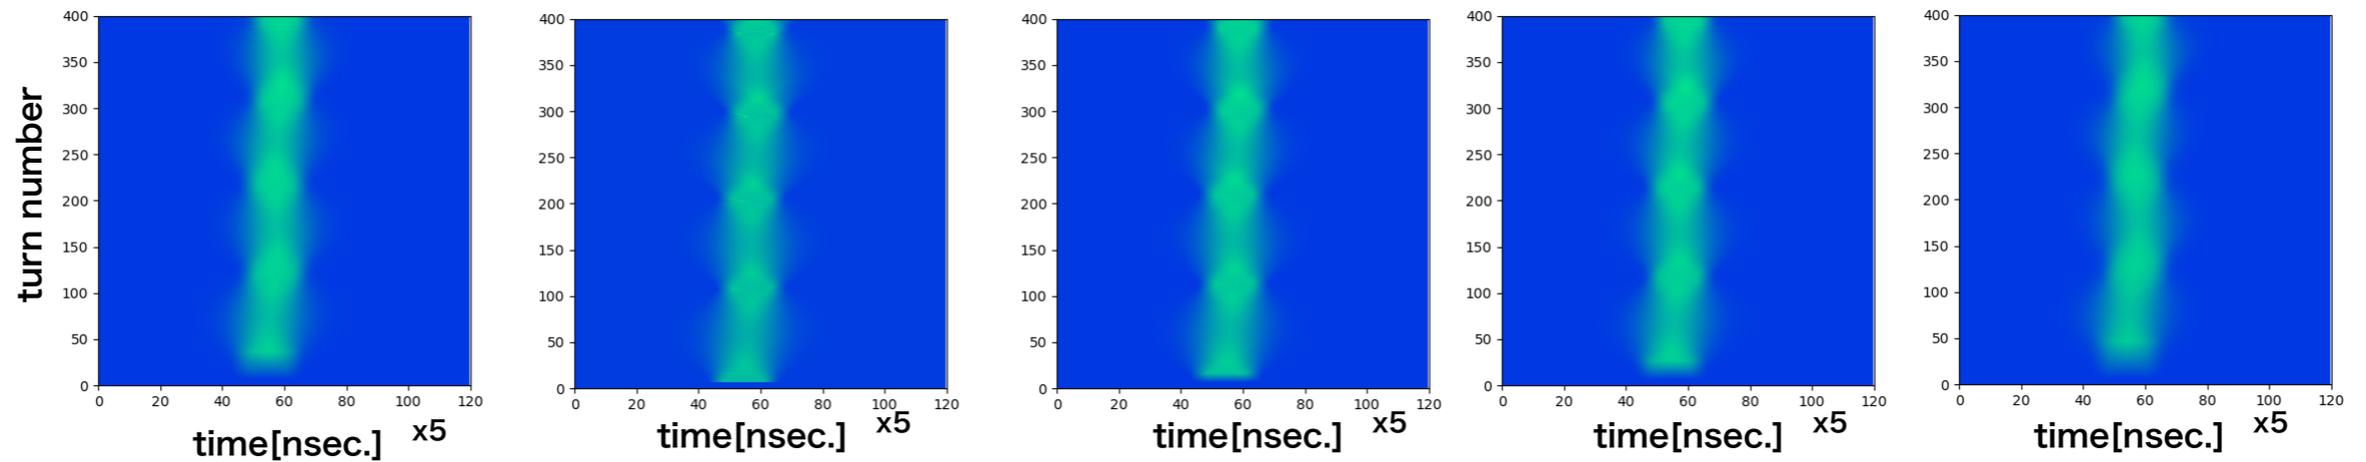
CVAEによる画像生成



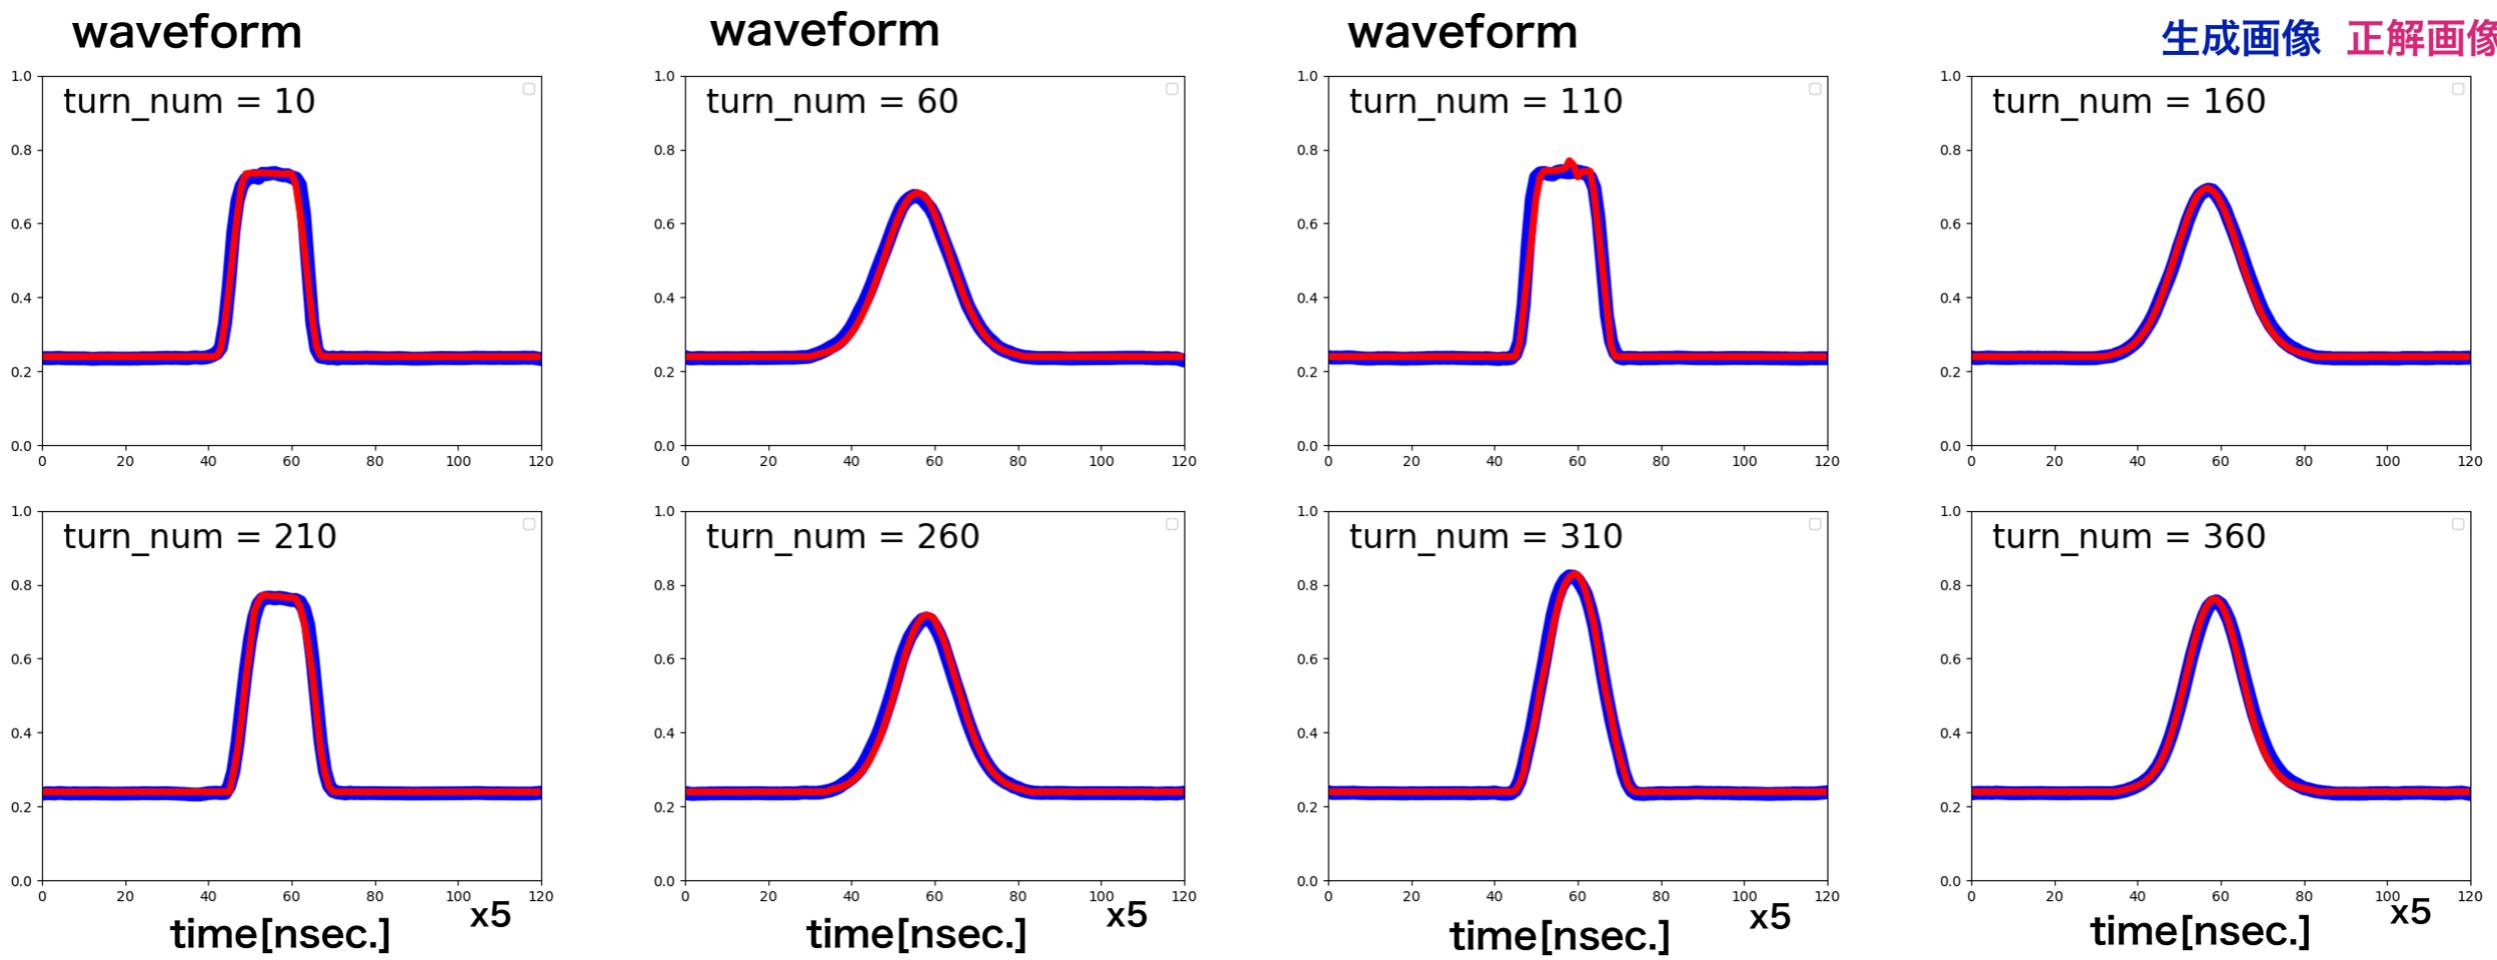
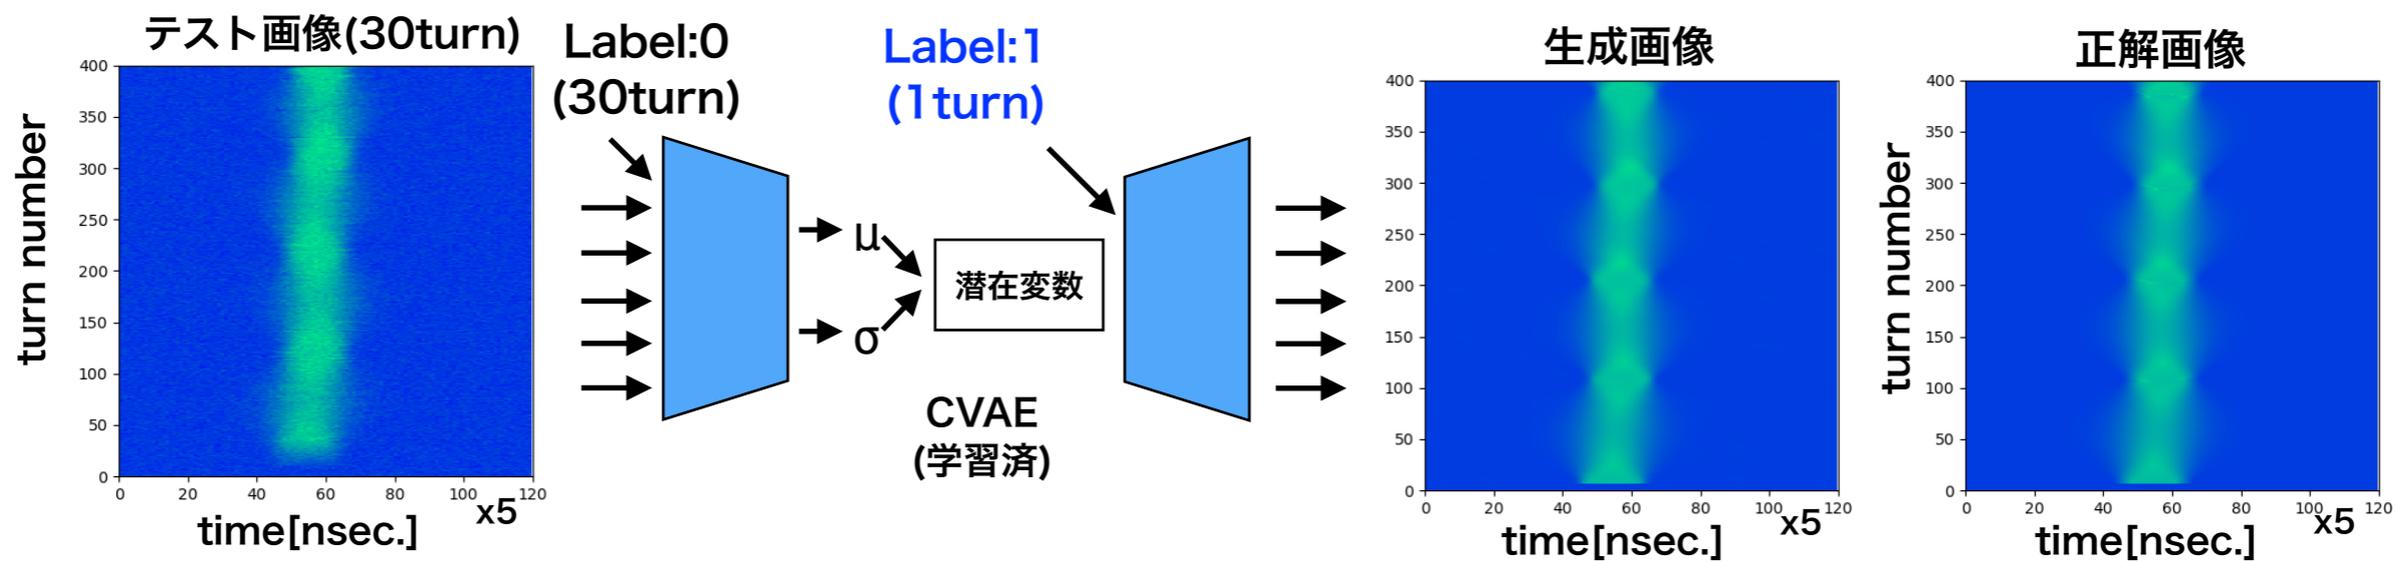
生成画像



正解画像
(平均化)

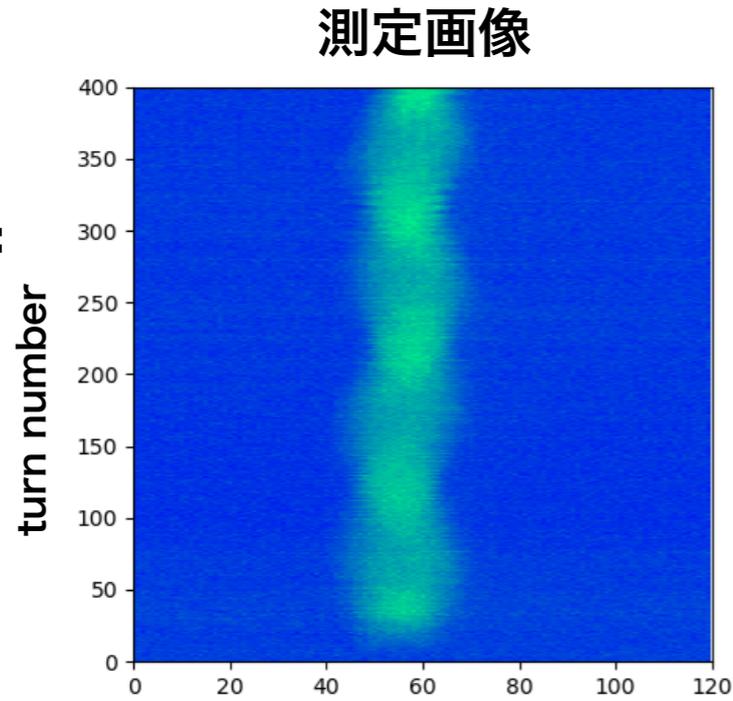


テスト画像により検証

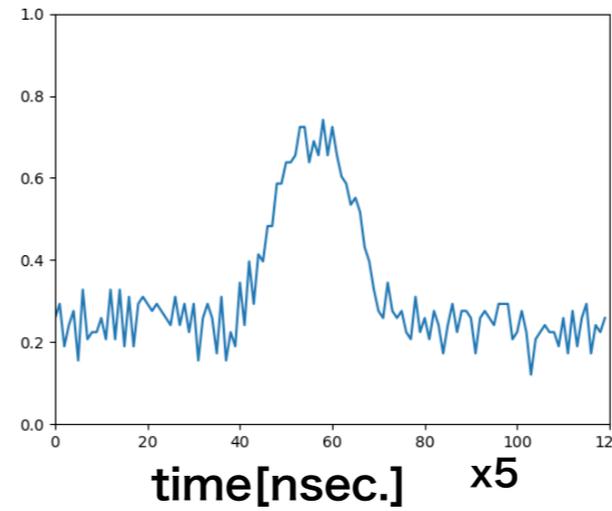


測定した mountain plot に適用

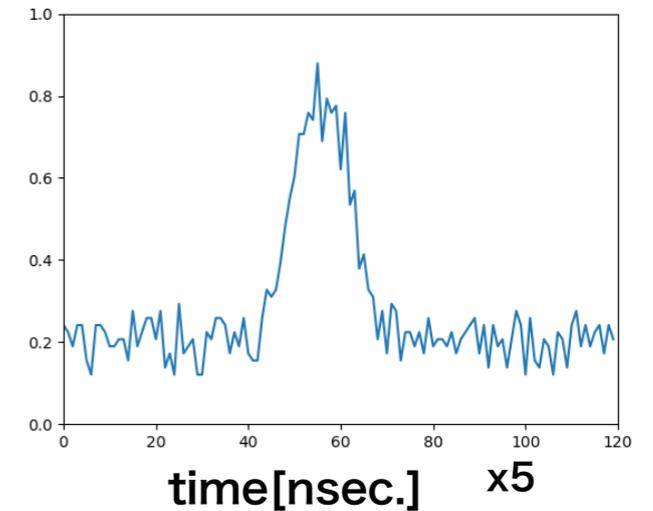
入射ターン数:
30



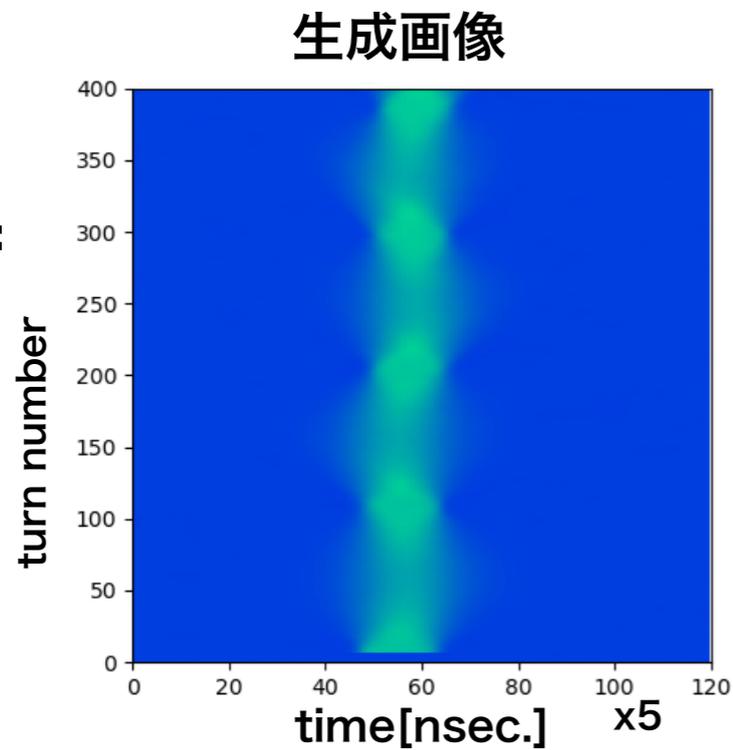
turn number: 60



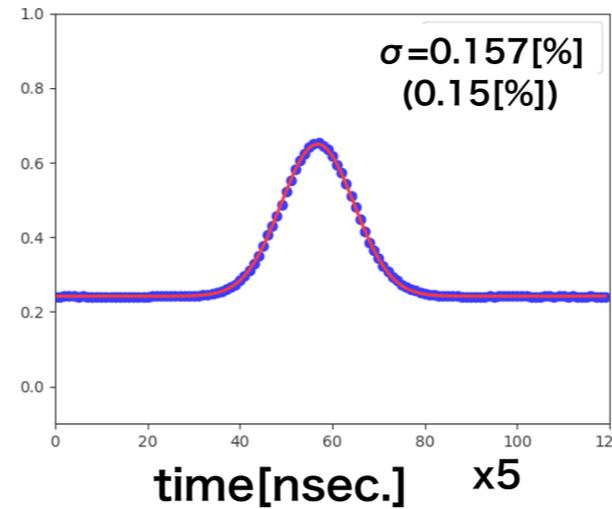
turn number: 110



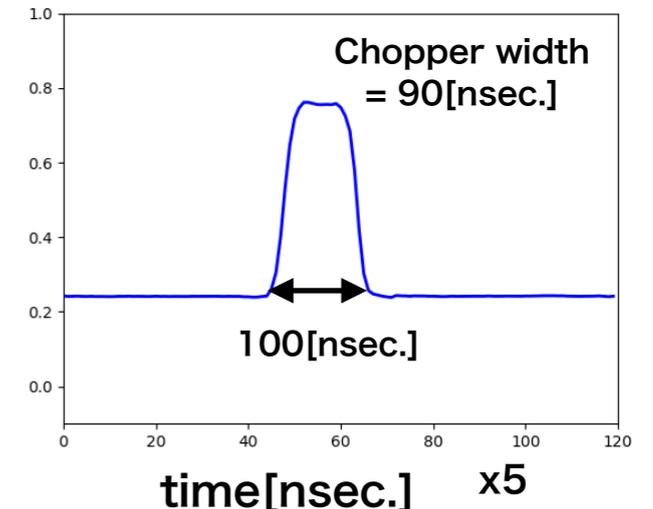
入射ターン数:
1



turn number: 60

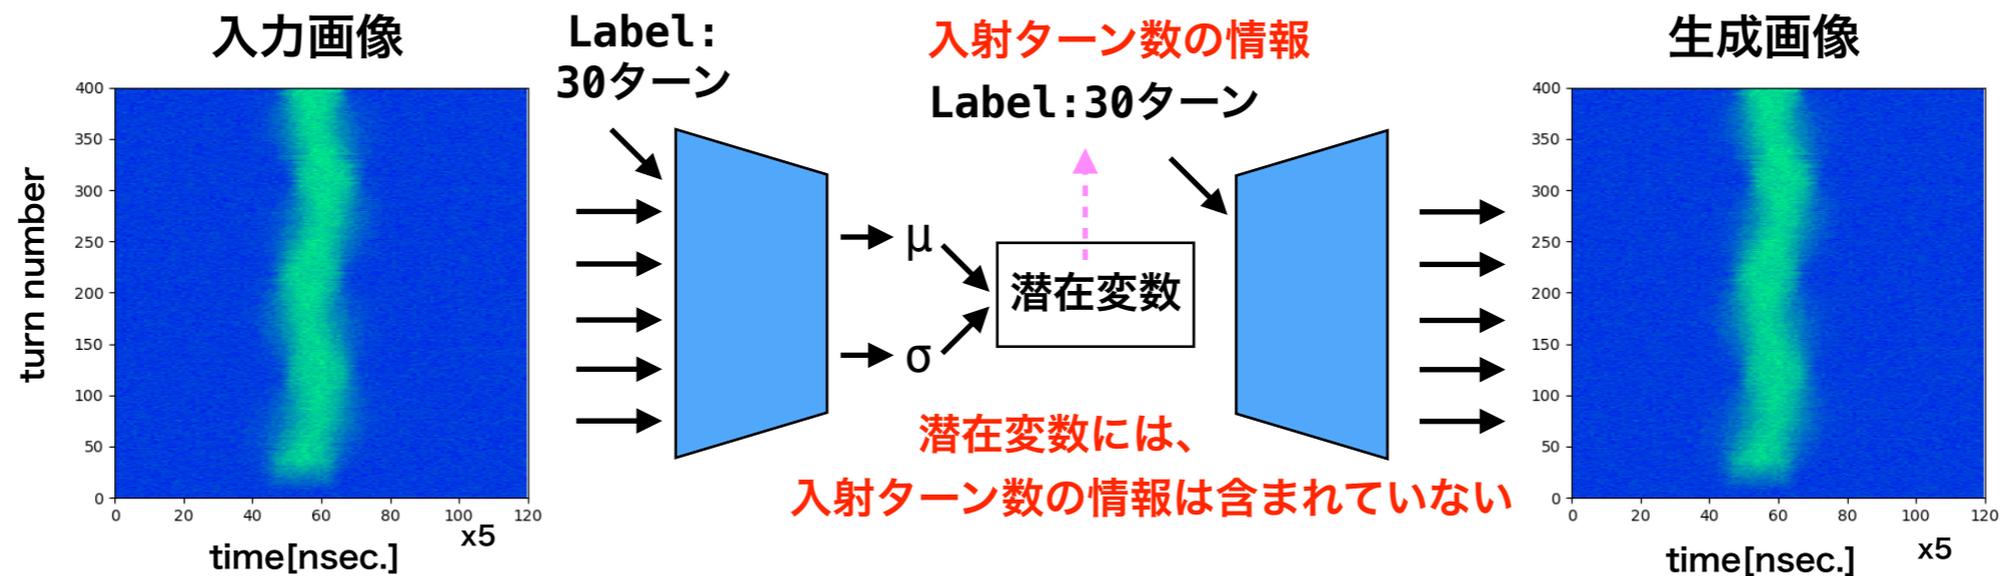


turn number: 110



なぜこの様なことができたのか

AEやVAEでは、入力画像を表す全ての情報を潜在変数として保存している。



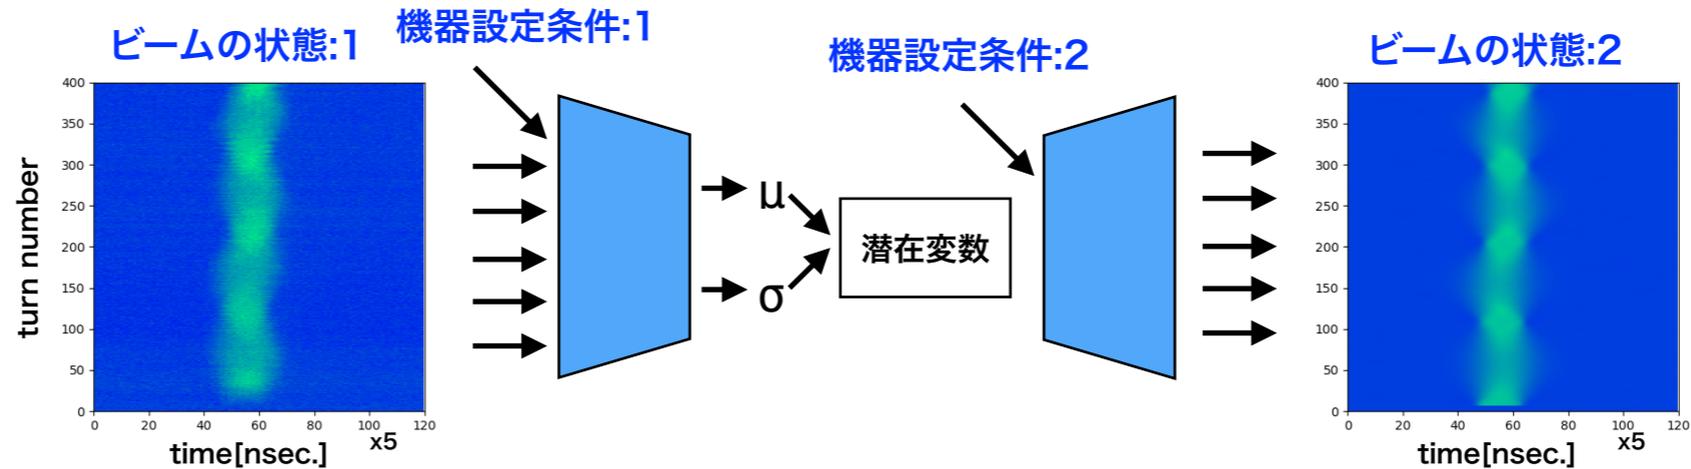
CVAEではその構造上(ラベルを導入)、

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事により、

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。

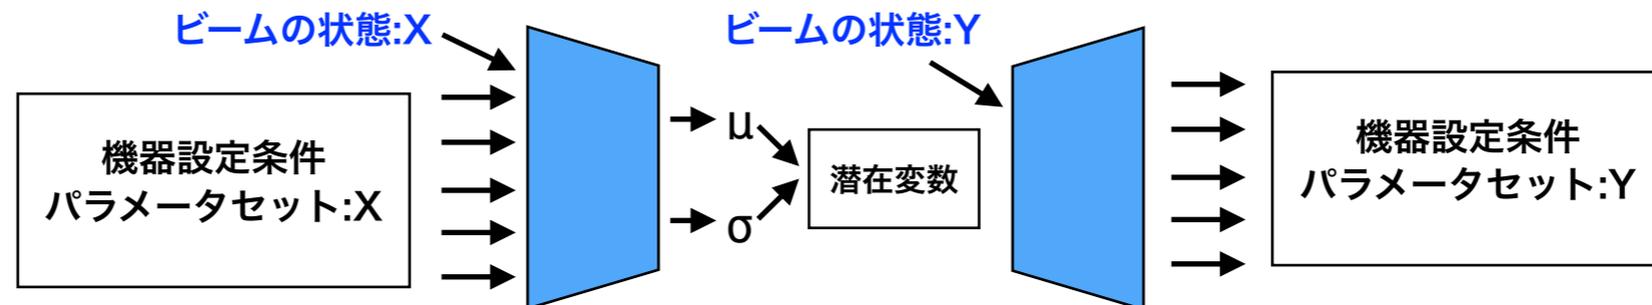
CVAEの特性を活かした加速器での利用

ここまでは、



ビームの状態を表す画像から、機器の設定を変えた場合のビームの状態の画像を生成した。

発想を変えて、



機器設定のパラメータセットから、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。

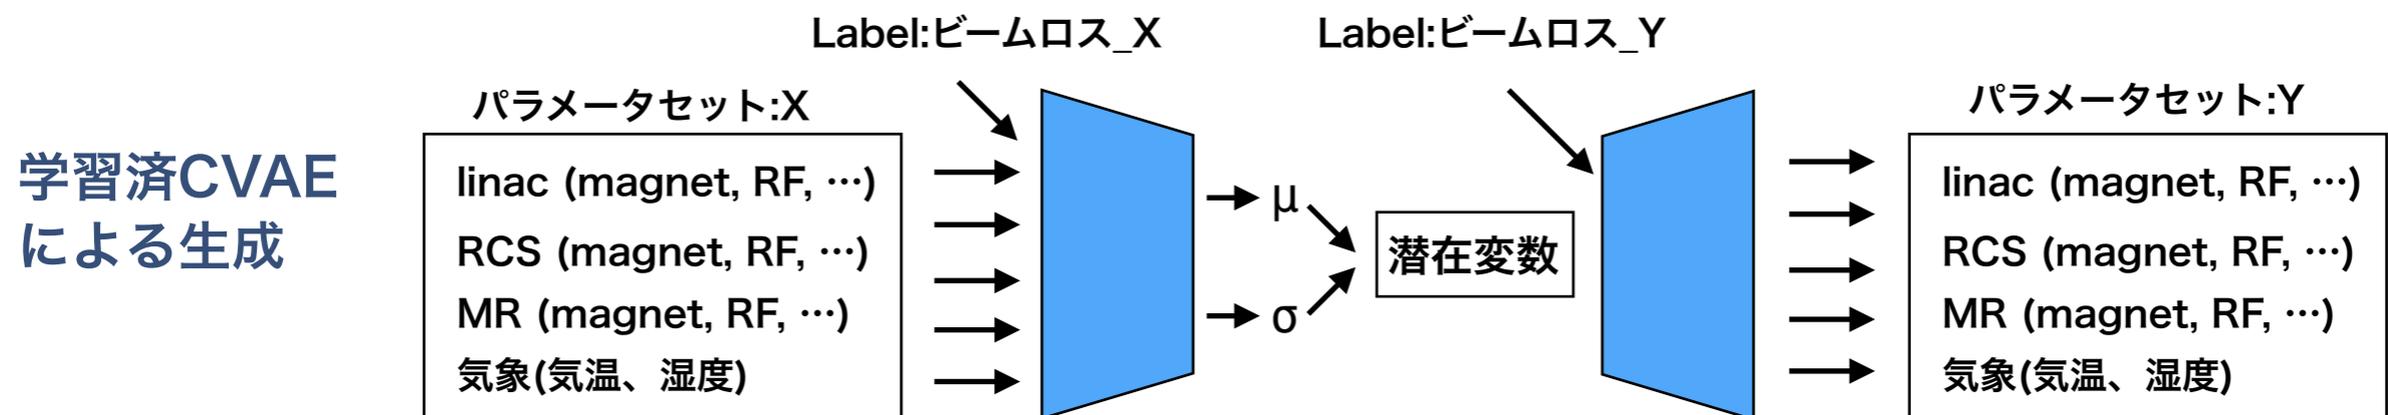
ビームの状態が変わったことにより
影響を受けた機器のパラメータは変わり、
影響を受けなかった機器のパラメータは変わらない。



どの機器がどれだけ
影響を与えたかが分かる。

もう少し具体的な描像として

ビームロスに影響を与える機器を探す。



ビームロスが変わった場合のパラメータセットを生成することができる。

➡ パラメータセットの中で、変わったパラメータがビームロスに影響を与えていた事が分かる。

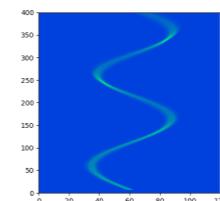
単純な場合で可能性を検証 mountain plot

mountain plotの振幅に
影響を与えるパラメータを探す。

パラメータ

- ① 入射タイミング
- ② 入射運動量
- ③ 時間幅
- ④ 運動量分布

ラベル(4)



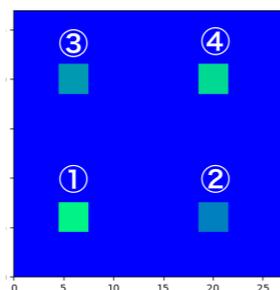
mountain plotの振幅

Label:0(振幅最小)

～ Label:3(振幅最大)

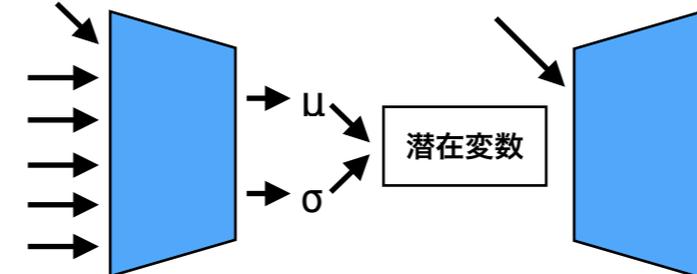
学習済CVAE
による生成

Label:3(振幅最大)の
パラメータを表す図

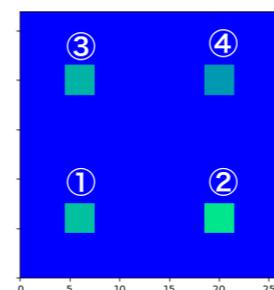


Label:3

Label:0~3



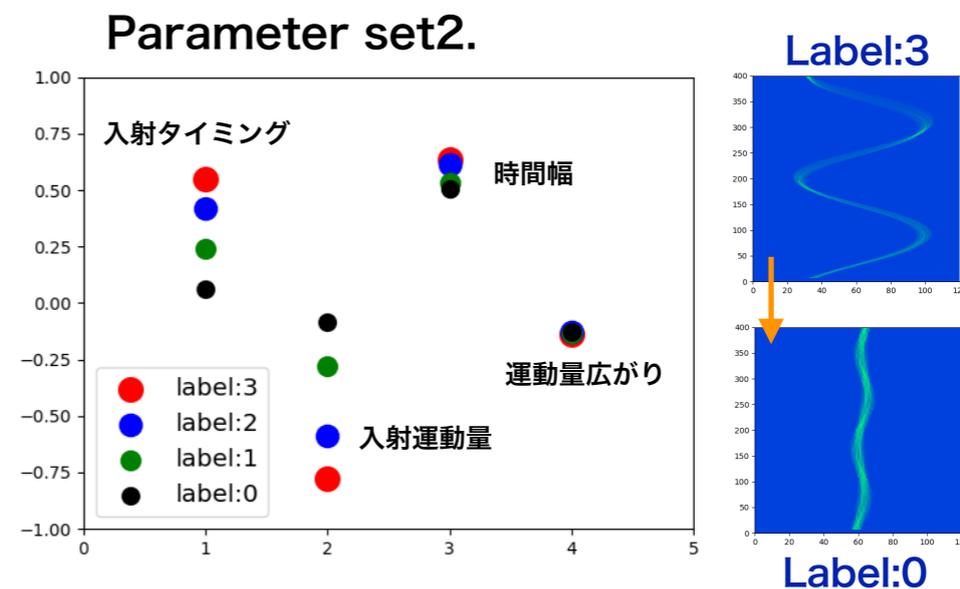
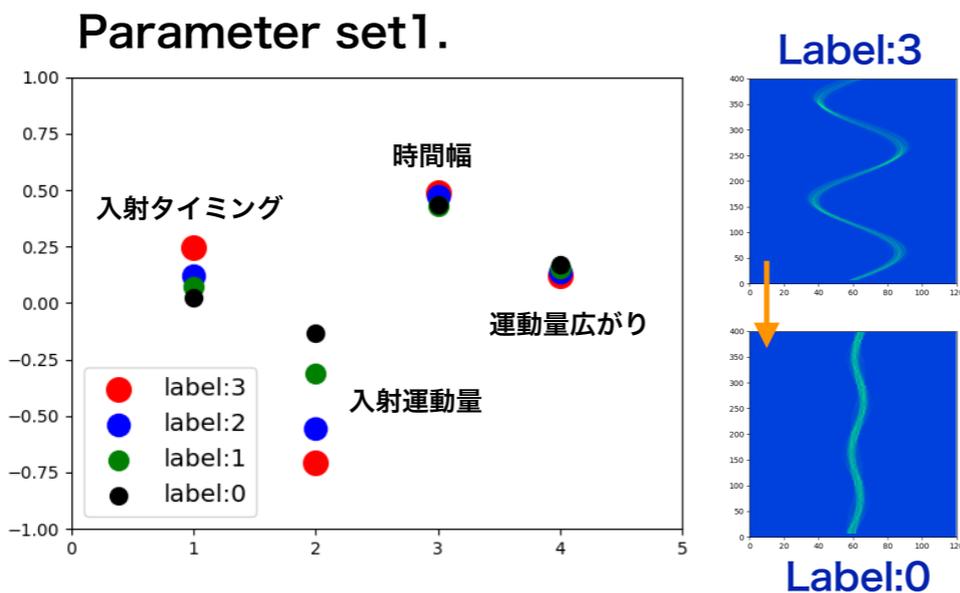
Label:0~3の
パラメータを表す図



ラベル毎に生成された
画像から各パラメータ
の値を求める。

結果

Offset



非常に単純な場合ではあるが、

確かに振幅に影響を与えるパラメータが大きく変わっている事が分かる。

感想

生成モデルであるCVAEに可能性を感じるが、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、

更なる検証が必要と思われる。

教師無し学習なので、実際のデータでも行えるはず。十分なデータが得られるかが鍵。

