加速器・ビーム物理の機械学習ワークショップ2023

ニューラルネットワークによるマウンテンプロット画像の生成

Generation of Mountain Plot Image by Neural Network

Masahiro Nomura（JAEA J-PARC）

moutain plotとは

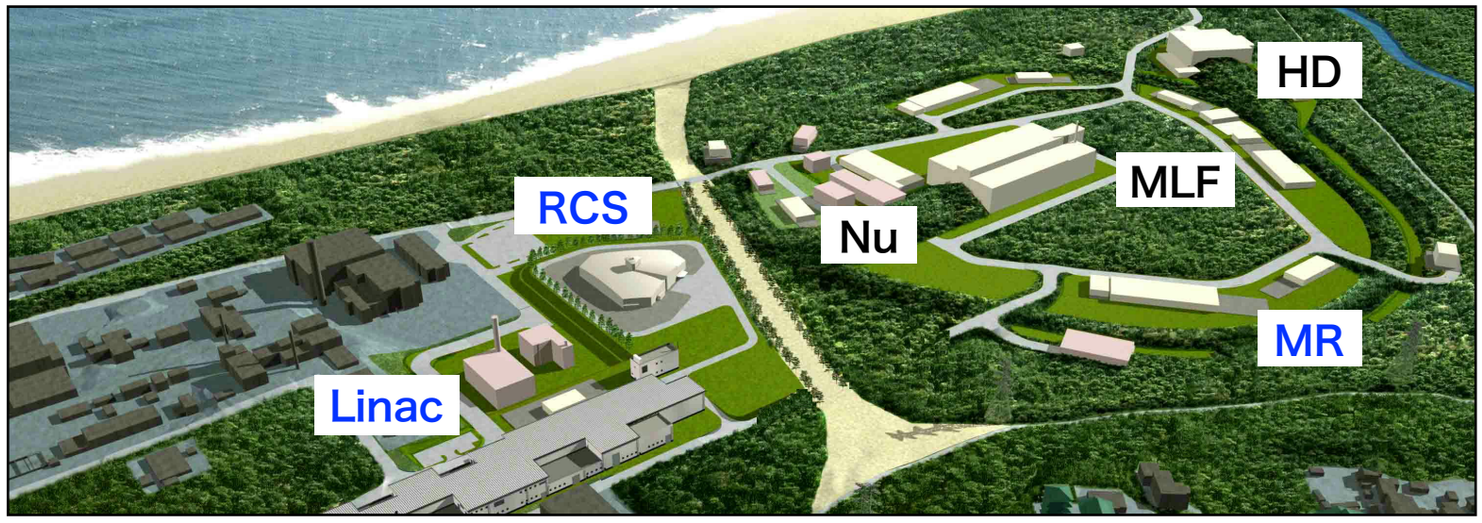

mounttain plotは RCS、MRへの
入射ビームの縦方向の振動等の情報を視覚的にも理解できる様にした画像。

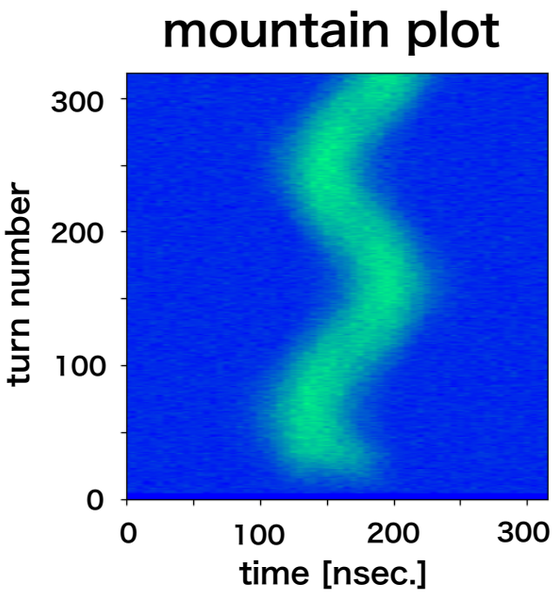

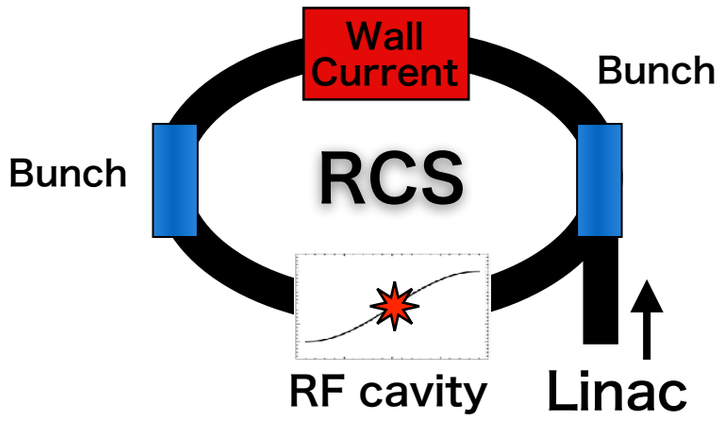

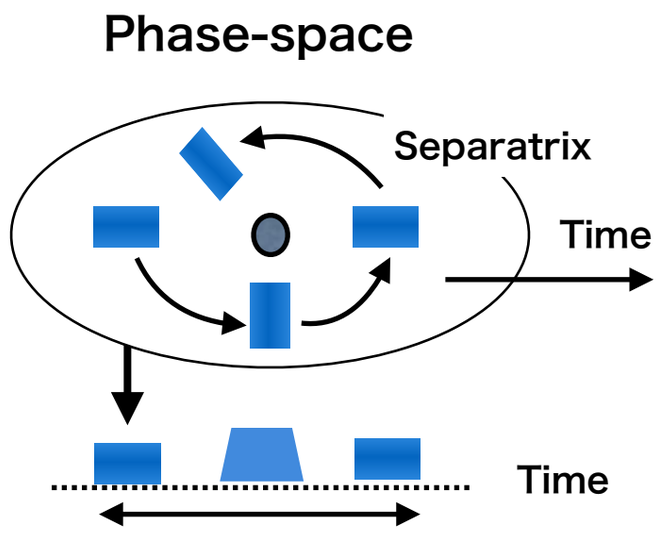

第一回では、
画像認識技術(CNN)により、
mountain plot から 入射時の位相空間上での分布を求めた

CNN:Convolutional Neural Network

Training
(Simulation)

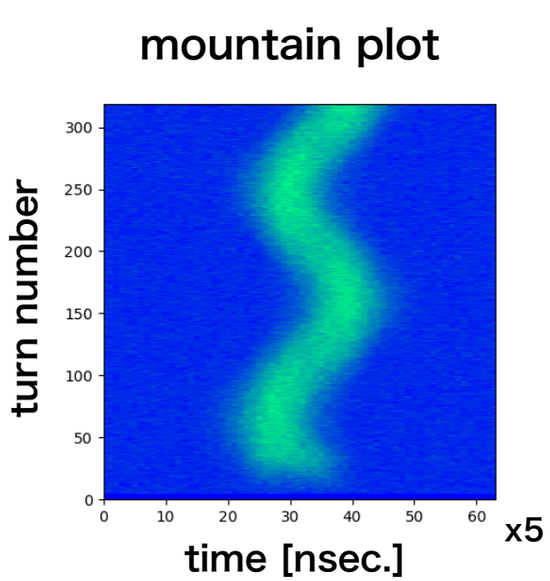

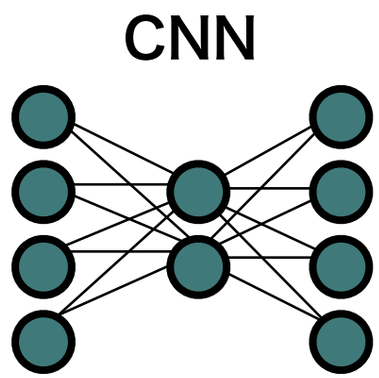

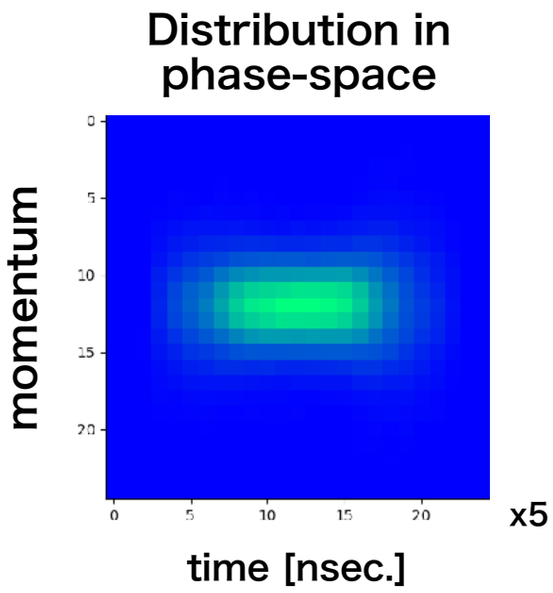

Prediction
(Measurement)

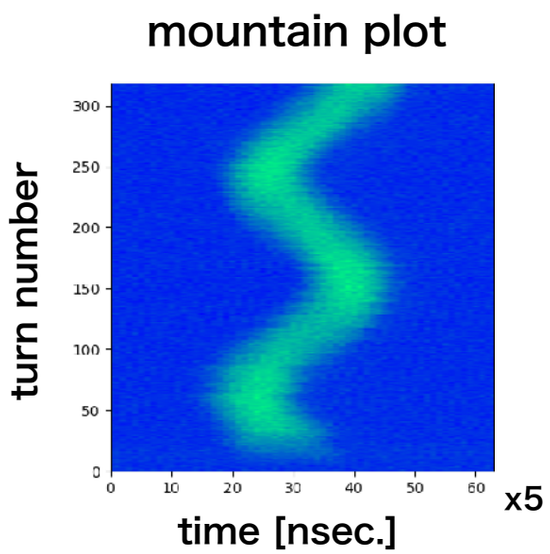

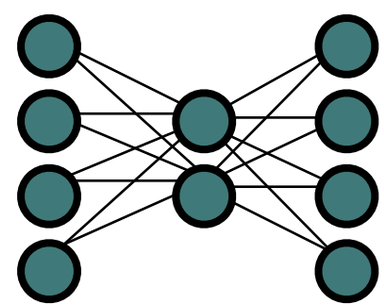

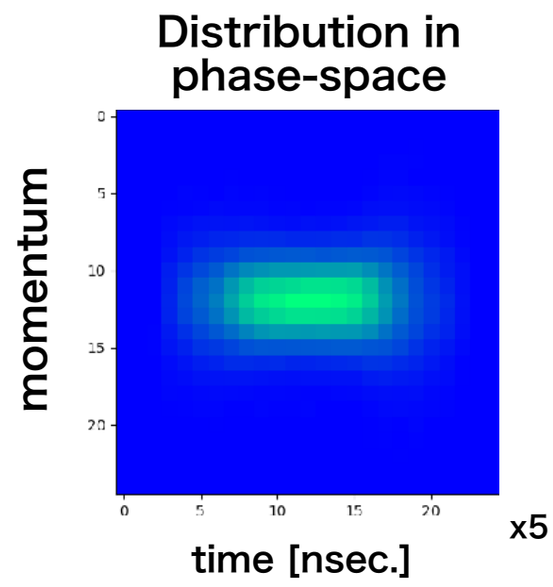

今回行ったこと、

Trainig dataの作成

入射ビーム：
タイミングoffset
運動量offset
＋

Phase-space

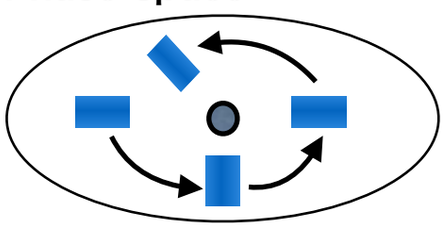

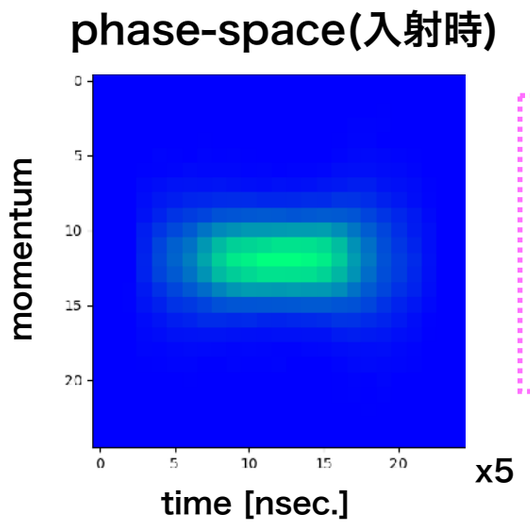

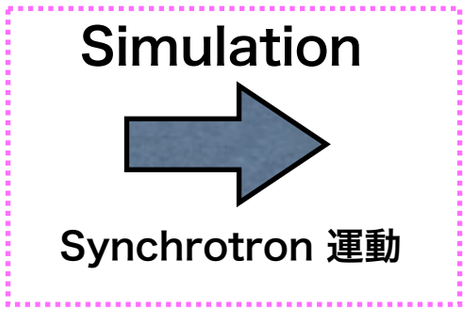

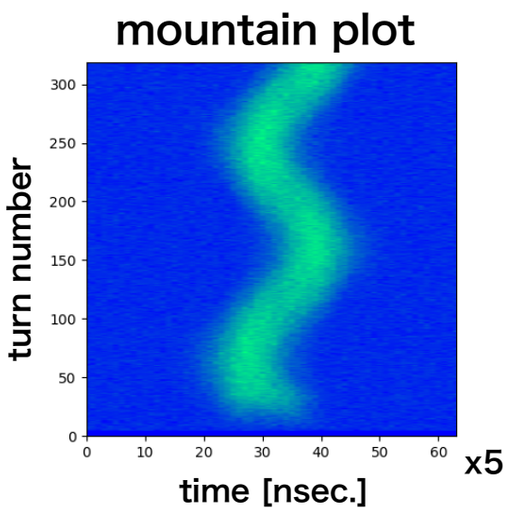

Neural NetworkでSynchrotron運動を学習し、
初期条件から、mountain plot を生成できないか？

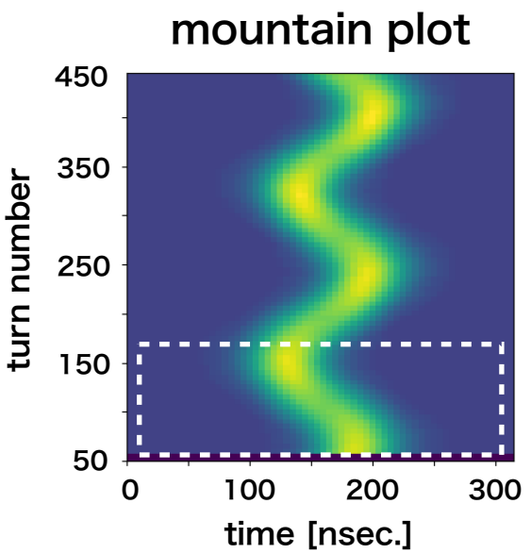

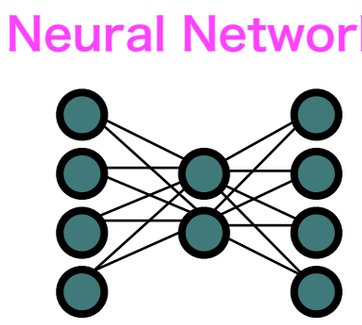

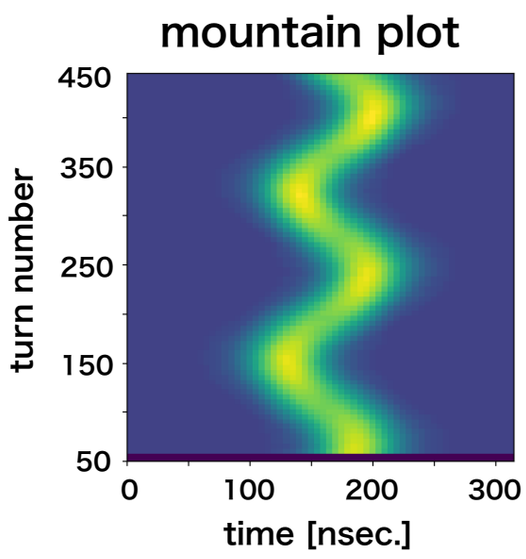

どうすればできるか？

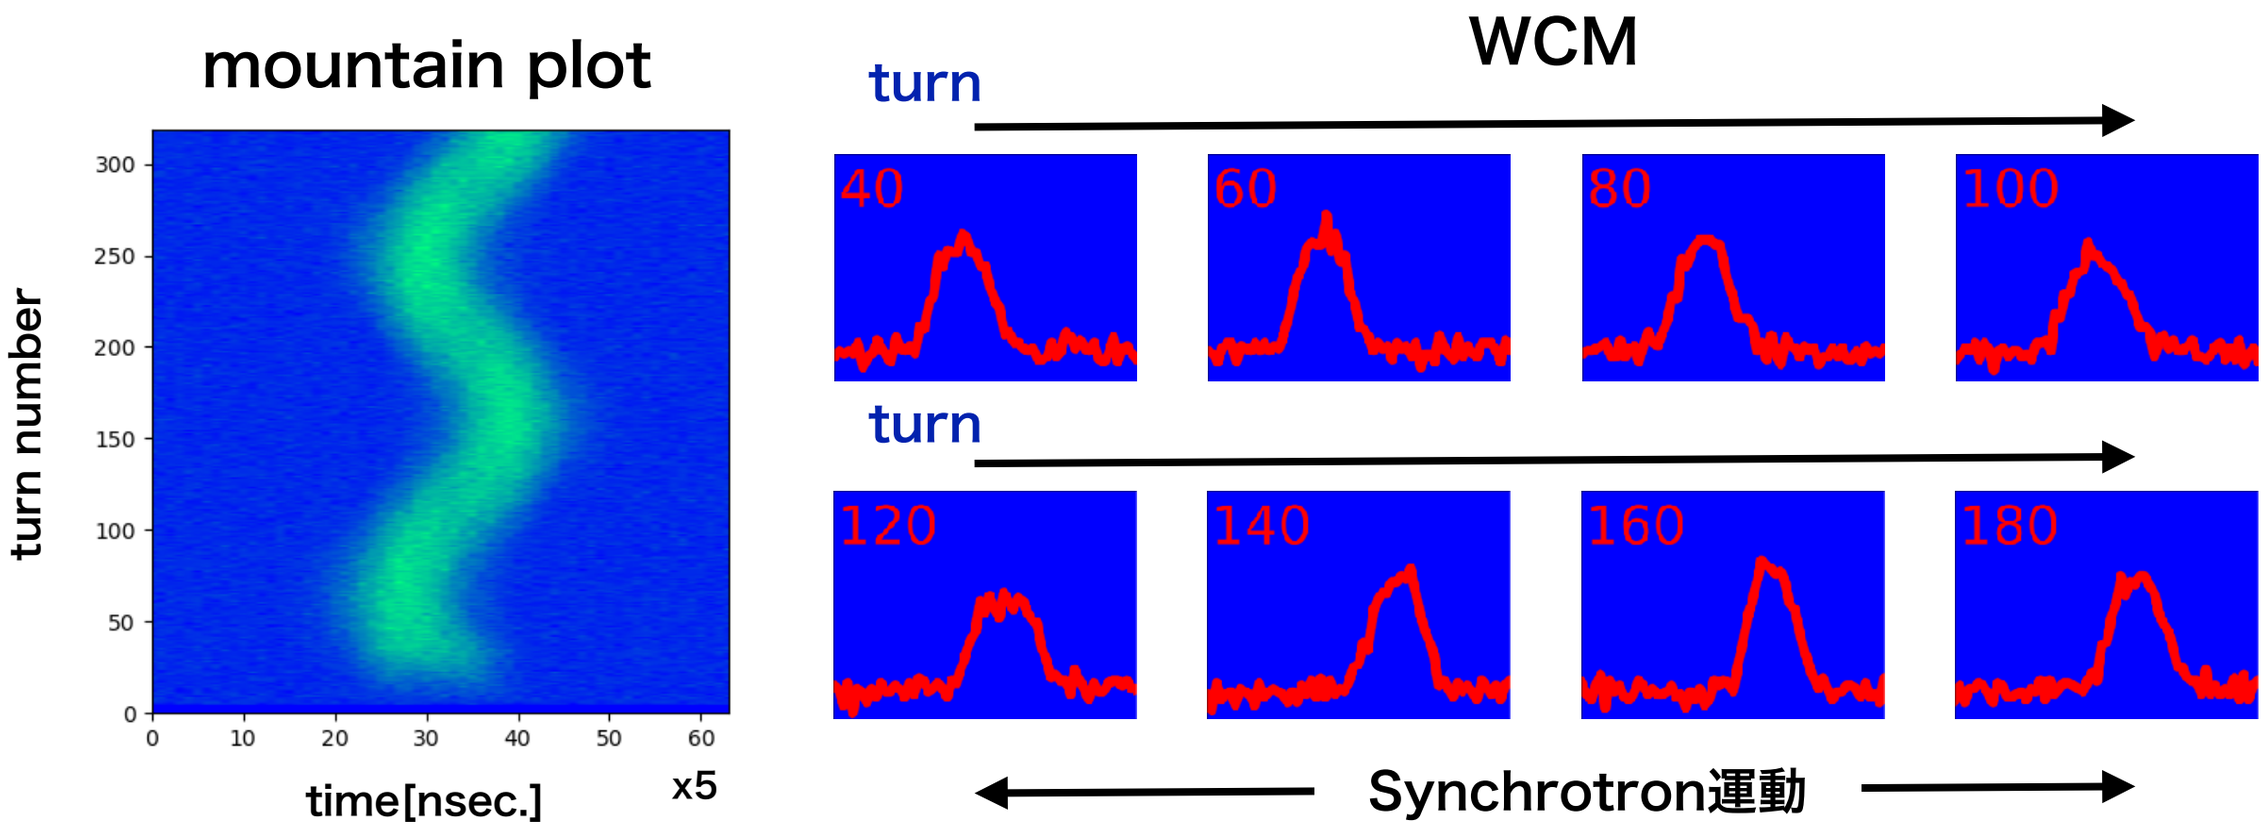

Neural Networkで、

WCMのturn毎の波形の変化を学習し、

次の波形を予測し生成できれば可能。

使用したNeural Networkは、

PredNet：動画を学習し、予測結果の画像を作成

Convolutional LSTM (画像と時間)

Predictive Codingという脳機能を基に考案

KITTI dataset
から引用

車の自動運転、気象予測、流体力学

mountain plotに適用

Moving MNISTを用いて動作確認

Moving MNIST:シーケンスの予測・再構築を評価するためのテストセット。
手書き数字が画面内を動き回るように作られた画像の集まり

今回は、学習用として300個を使用し、変化を学習。

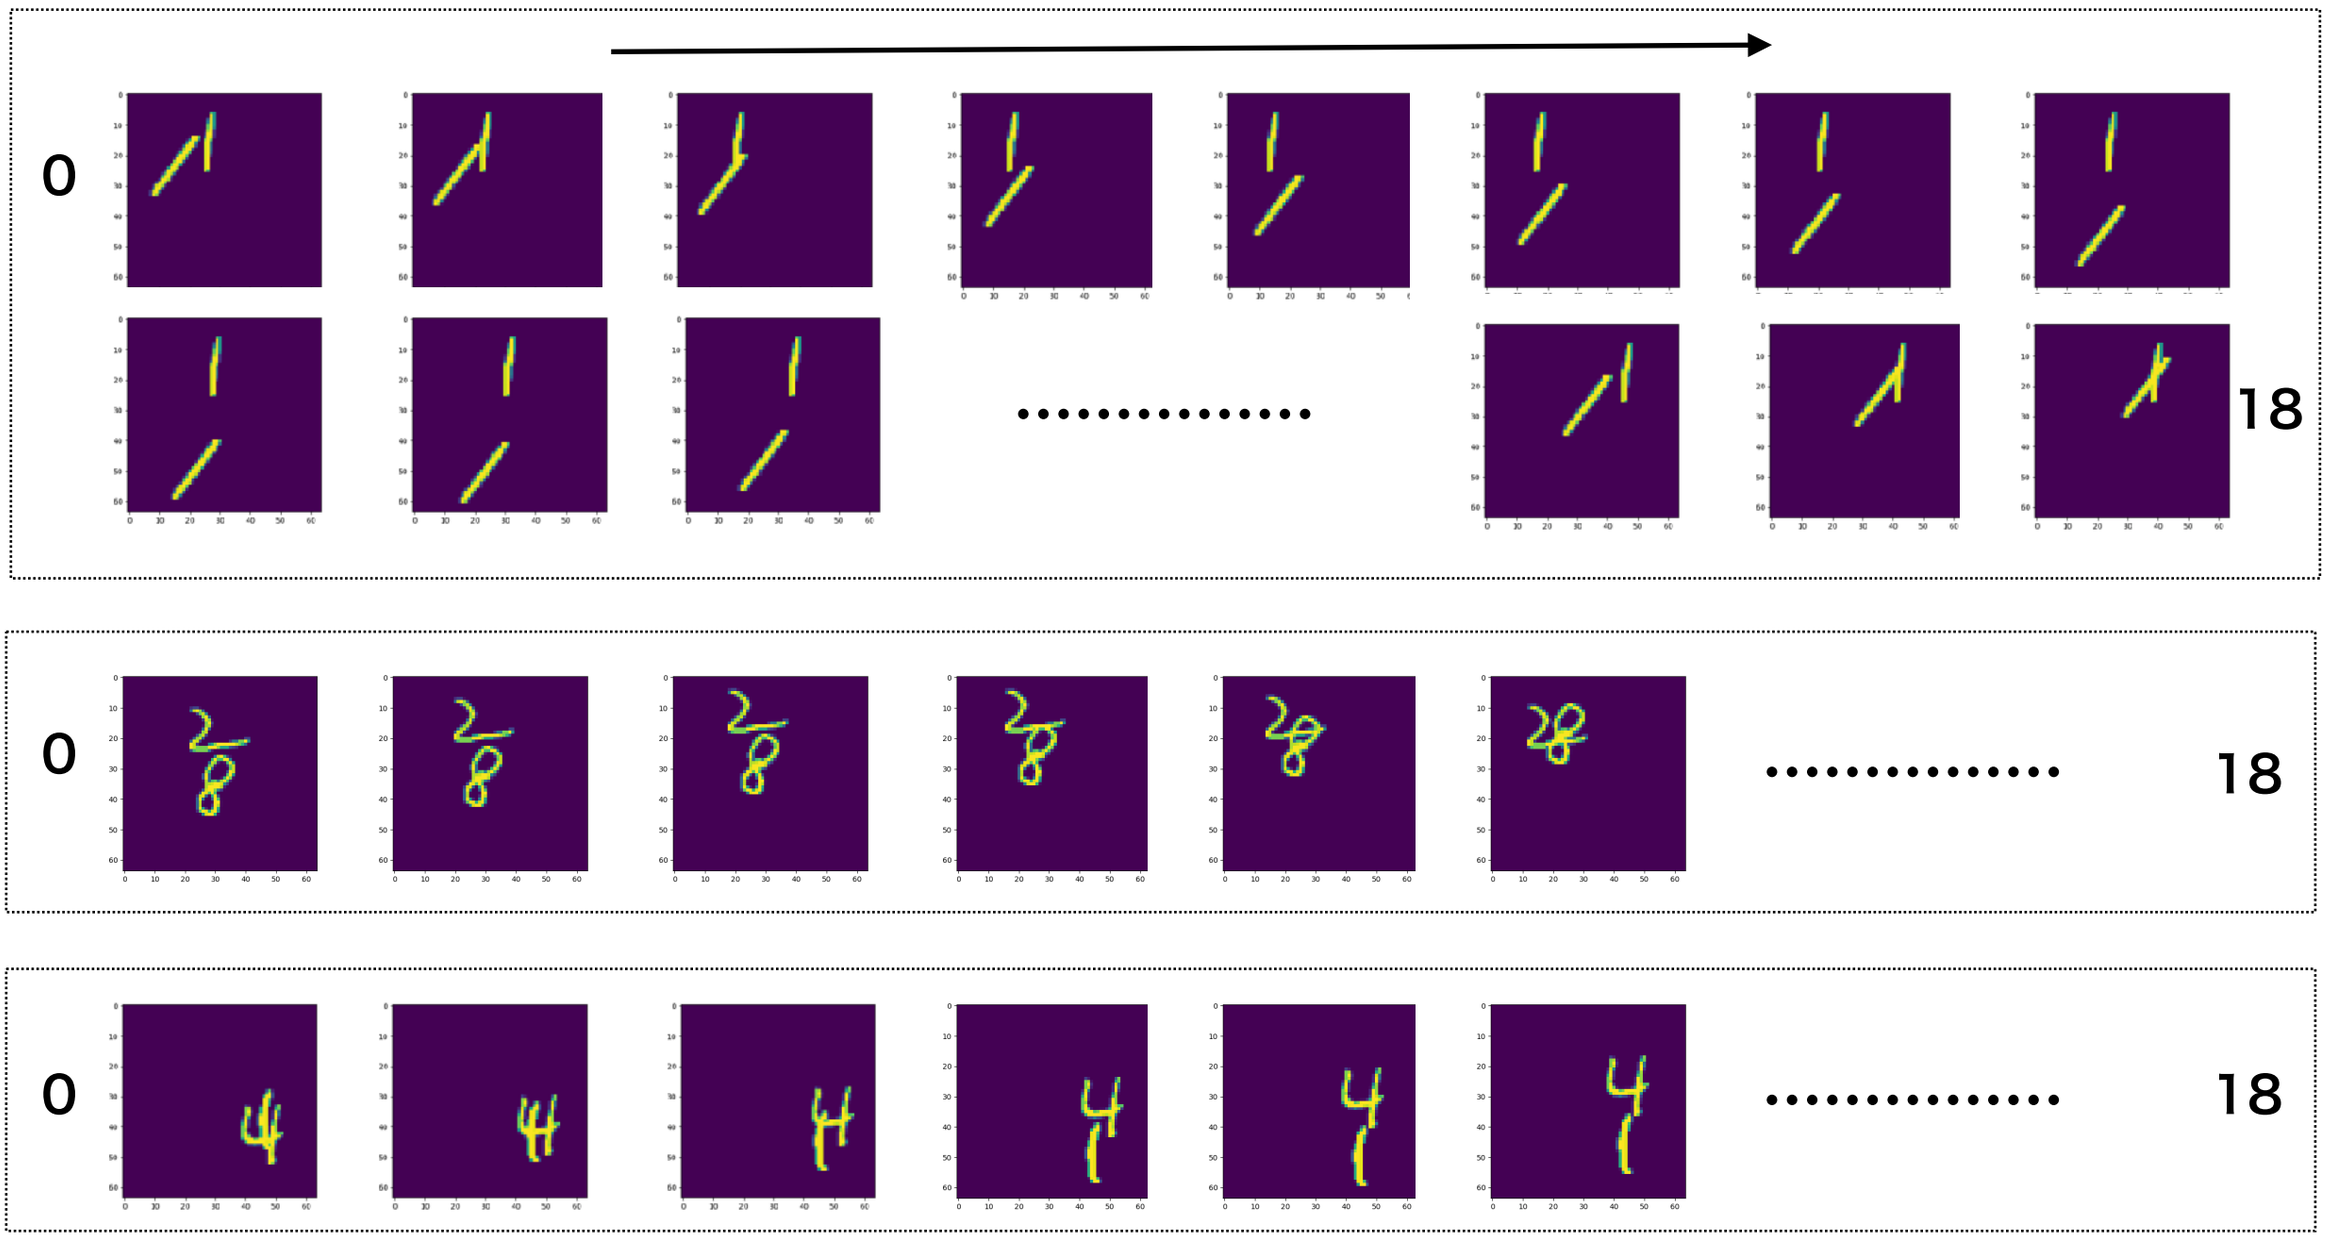

結果を、Test_data(学習に使用していない)で確認。

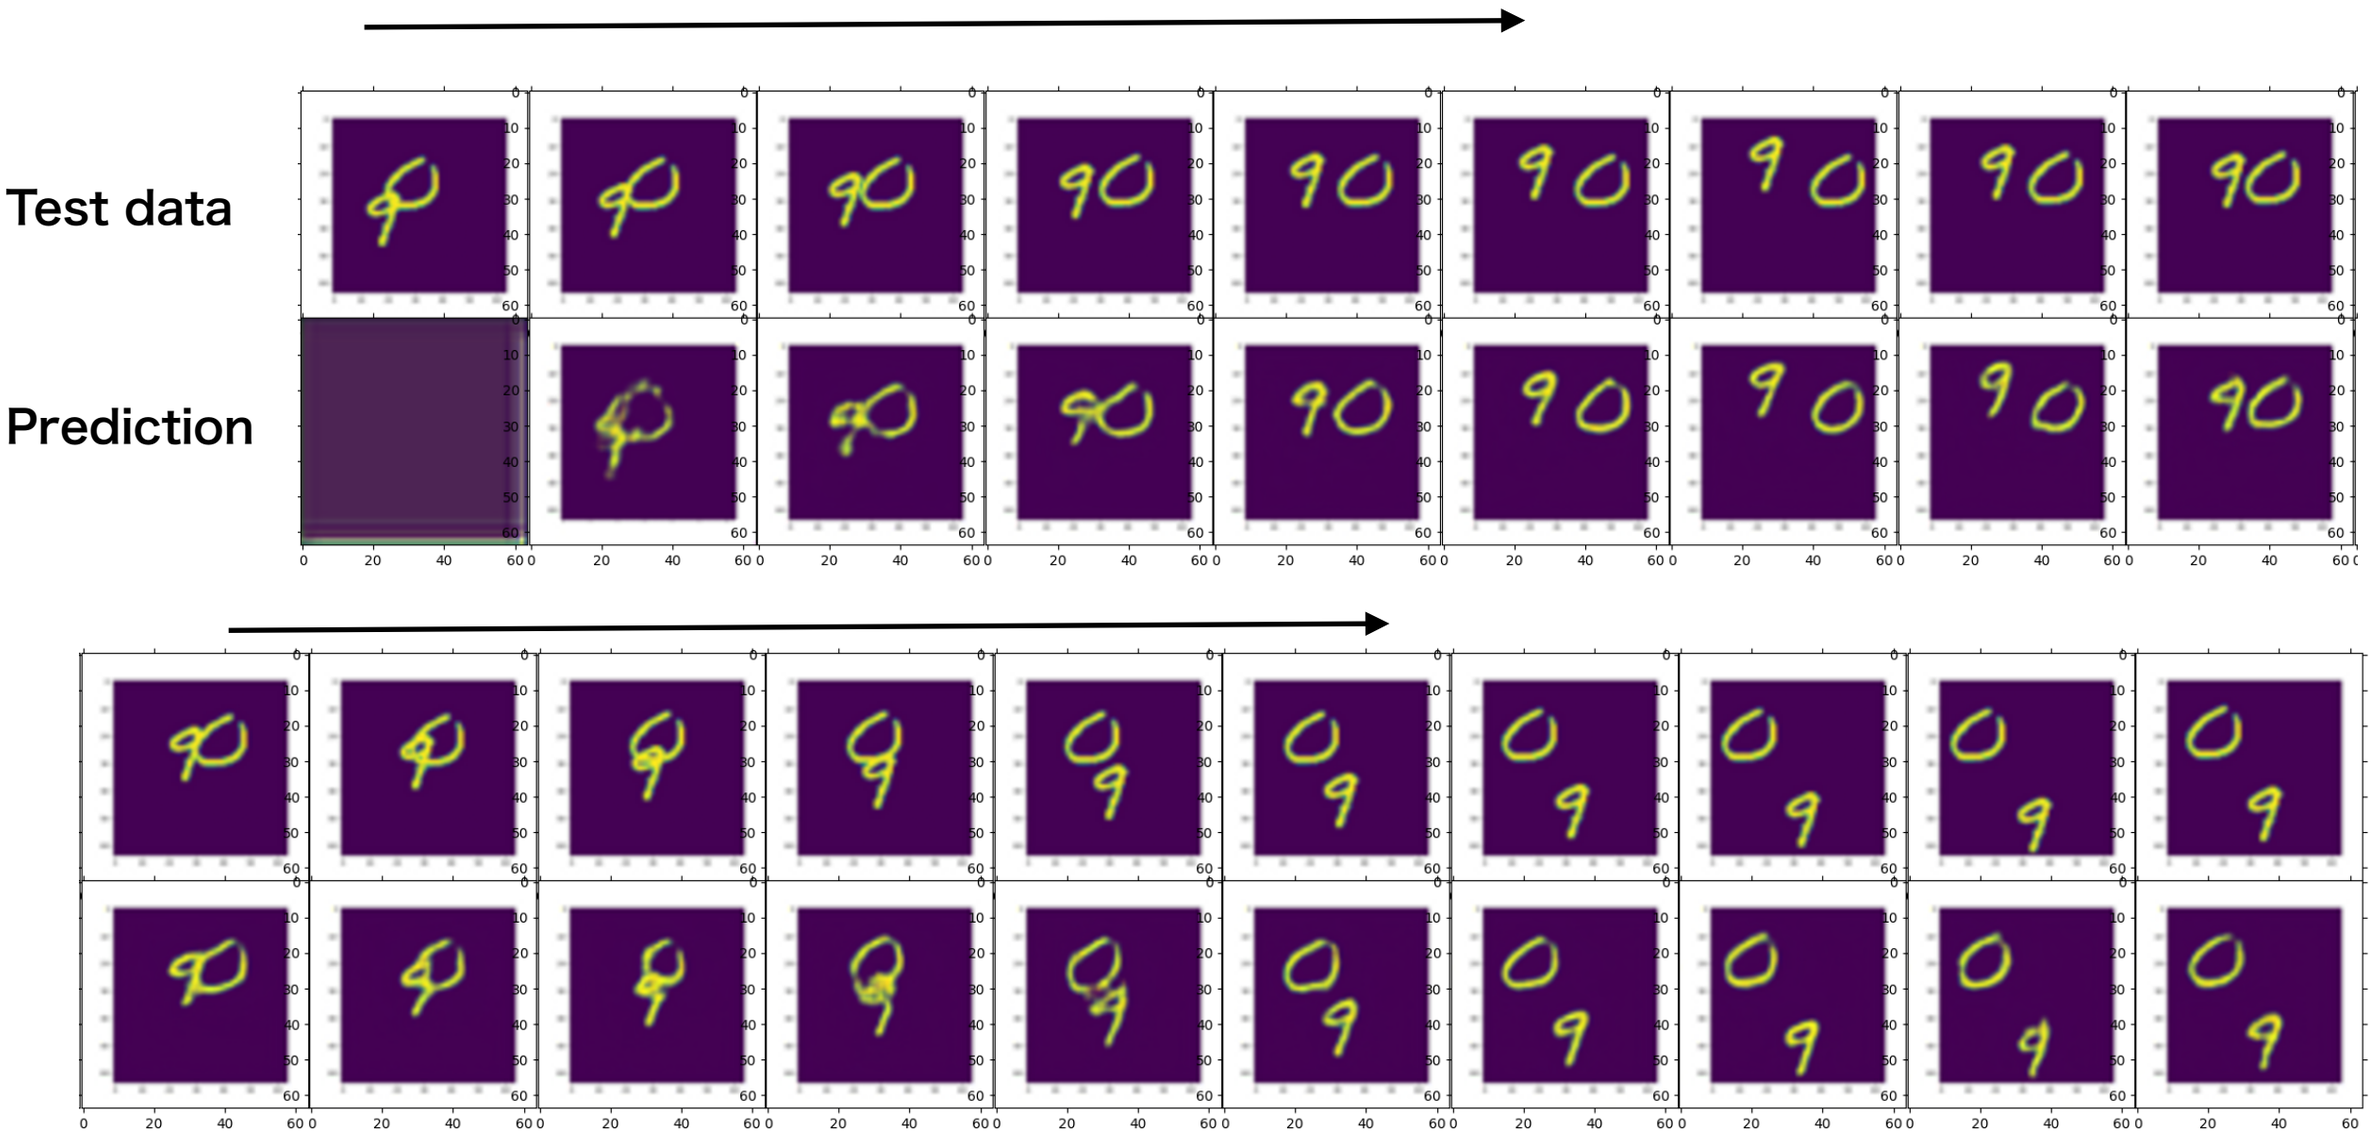

数コマ目以降、過去の動きから、先の画像を予測できている。

mountain plotへ適用、

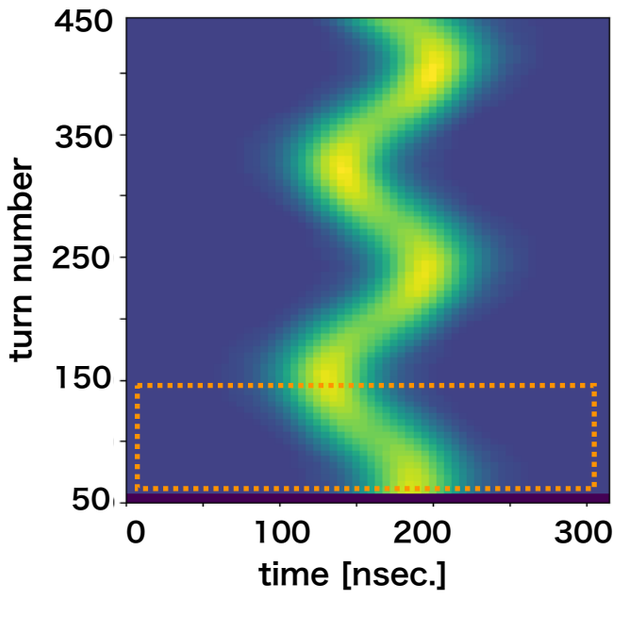

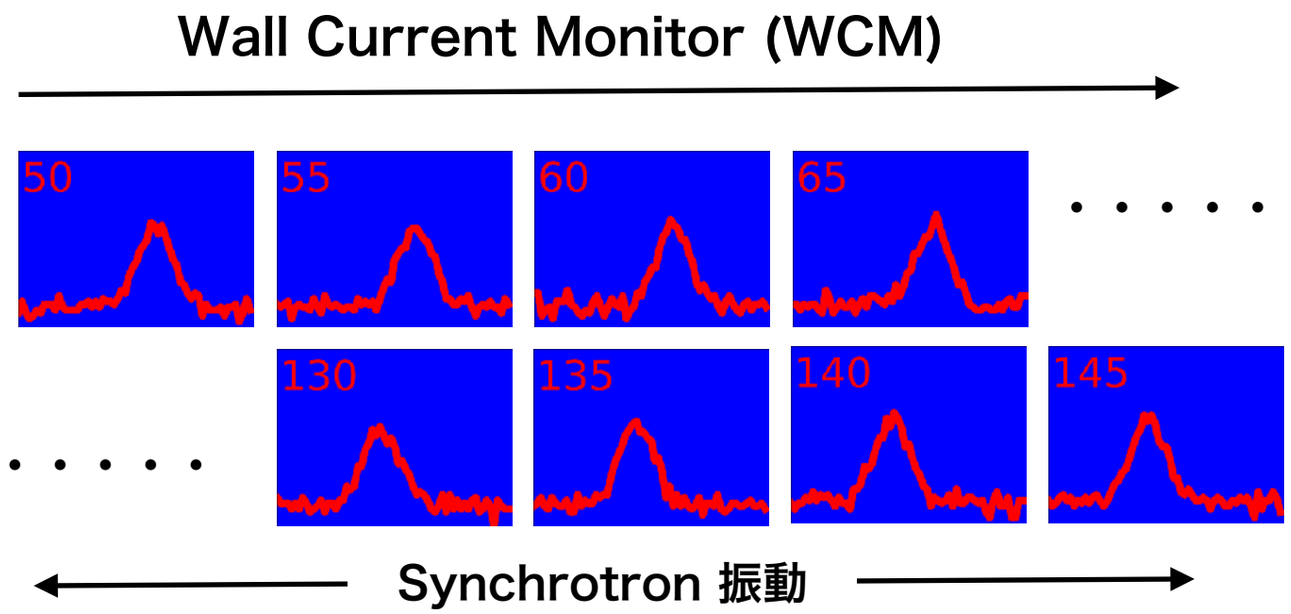

PredNetで学習し、予測画像を生成

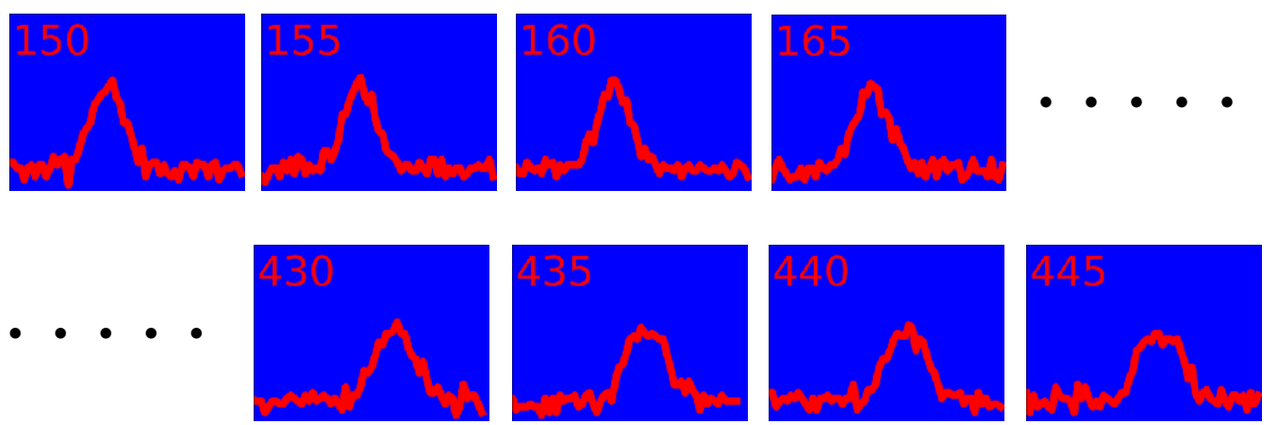

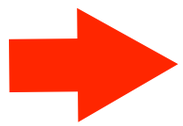

予測できるか？

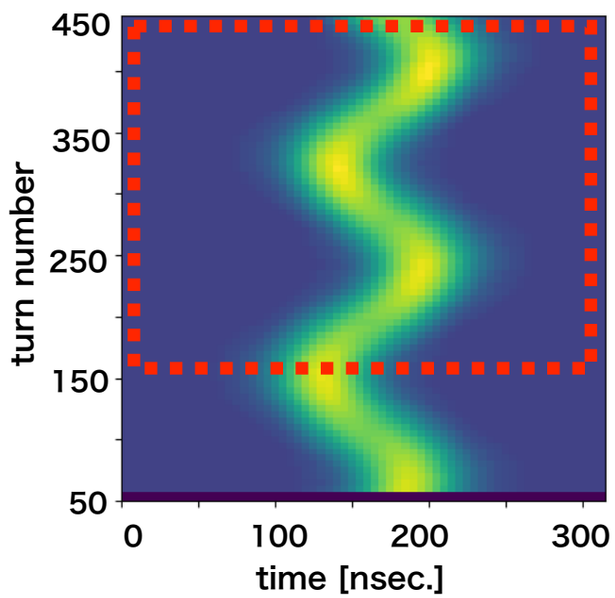

先ずは、学習画像を準備、

今回は、測定値が無いのでシミュレーション結果を使用。
mountain plotの測定値からも、予測画像が生成できるようにしたい。
→ 学習画像にはノイズとタイミングジッターを加ええる。

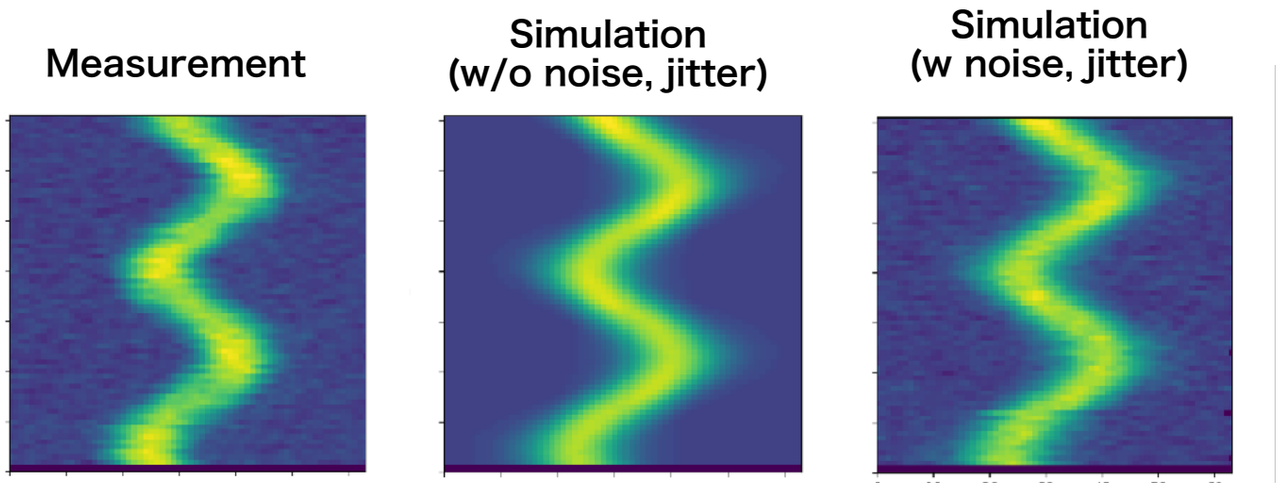

学習:200 data

mom. spread : 0.1 [%]
timing width : 90 [nsec.]
mom. offset : -0.3 ~ +0.3 [%]
timing offset : -60 ~ +60 [nsec.]
multi-turn inj. : 30 turn
学習：5 turn毎

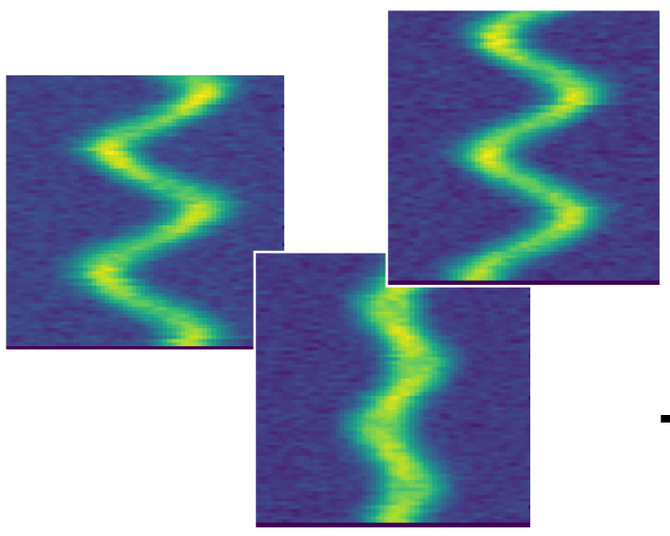

80 画像

学習画像

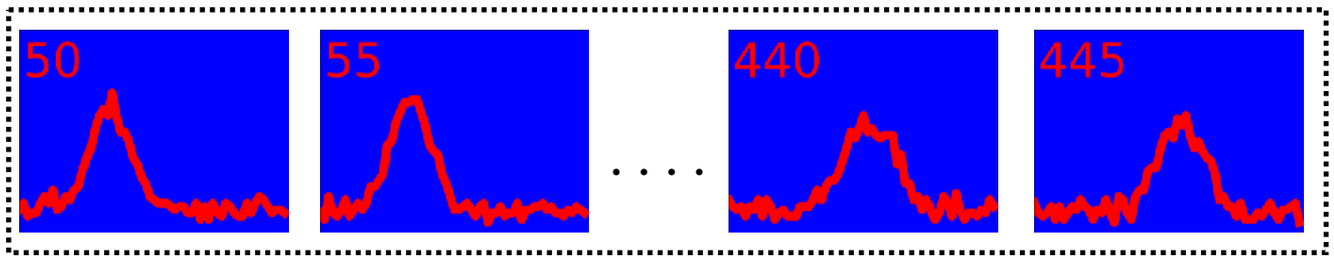

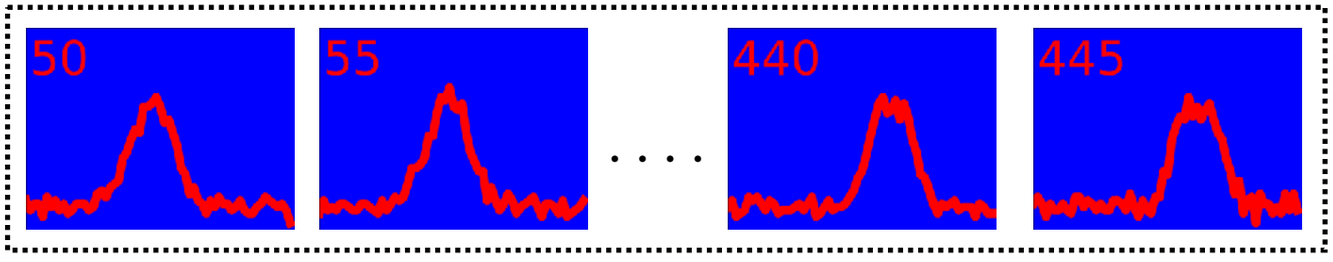

次は、学習

Step1:WCM 波形100ターン毎に、次のターンを予測できる様に学習。

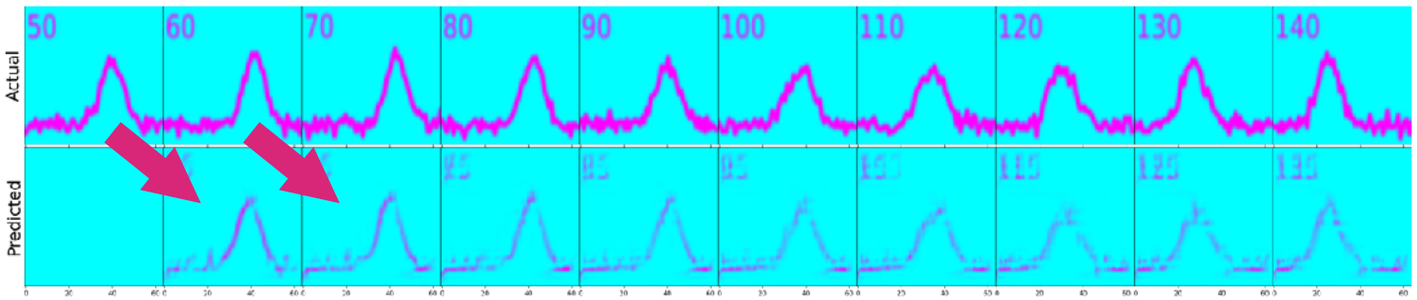

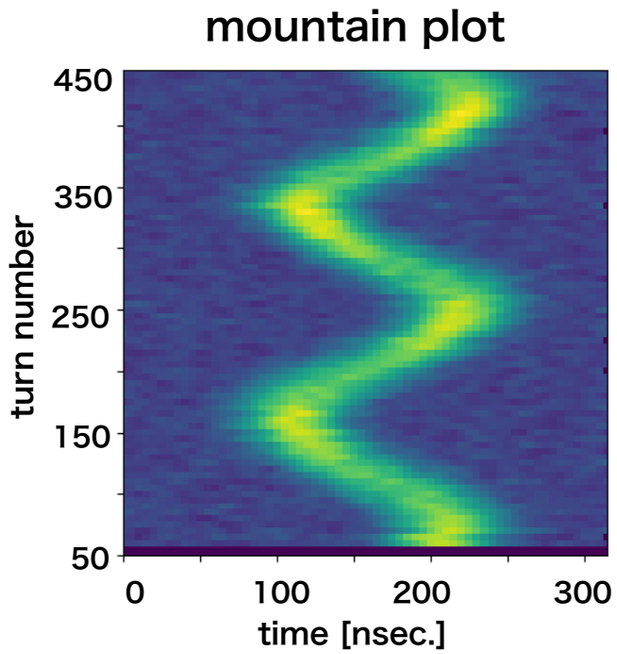

Step2:150ターン以降は、予測値を使用して、次のターンを予測できる様に学習。

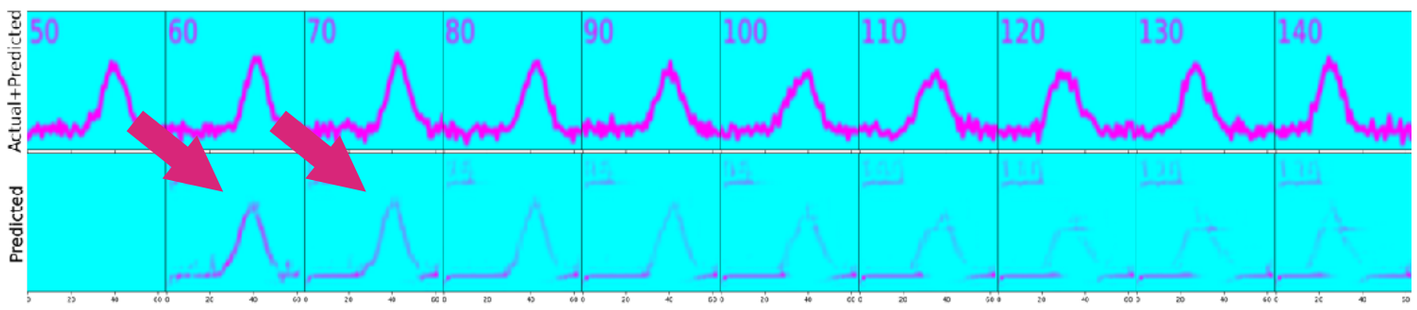

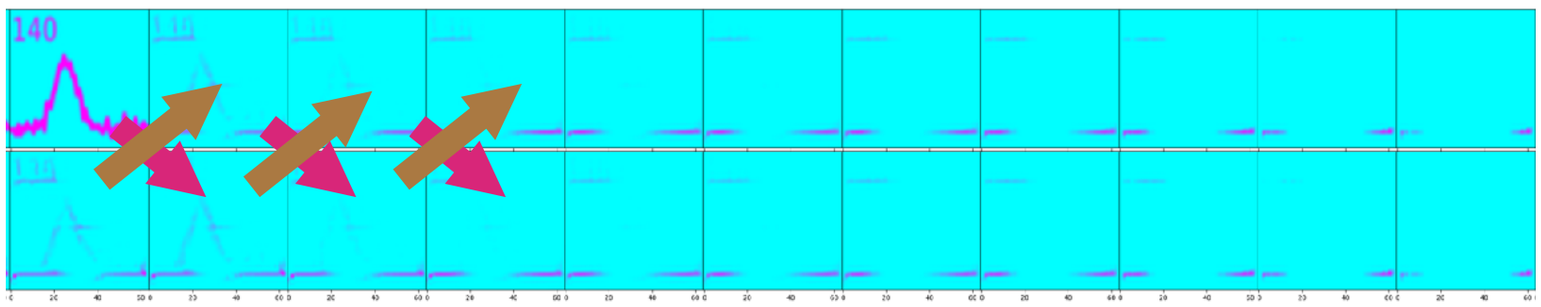

学習後の予測画像は、

10 turn毎に表示　　ターン数を予測している。

Test_data

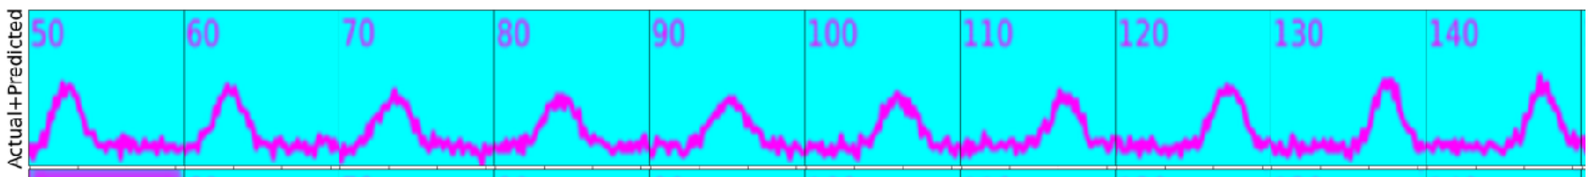

Prediction

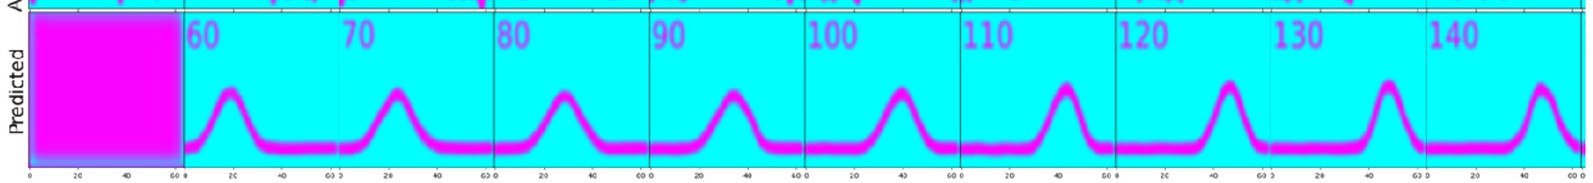

150 turn 以降は、予測値をTest_dataとして採用。

Test_data

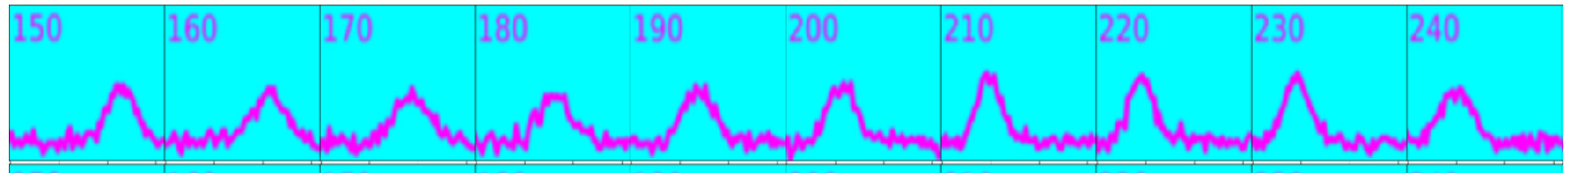

Prediction

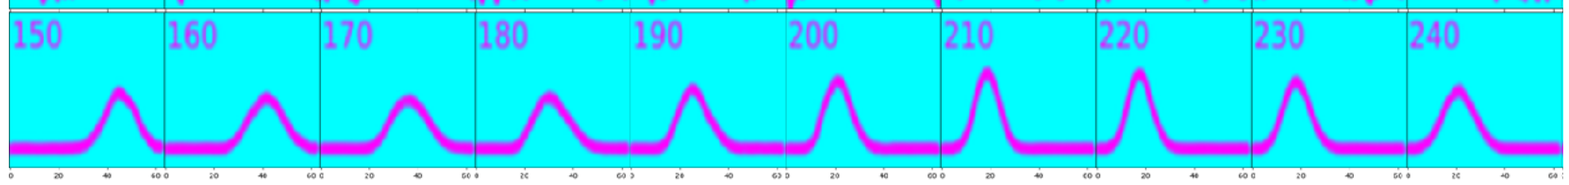

• • • •

Test_data

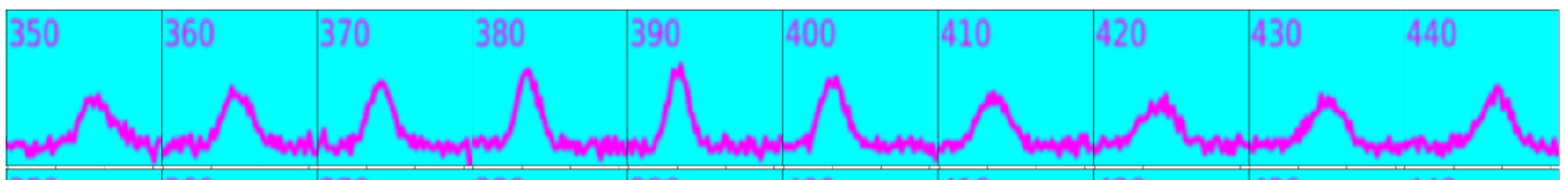

Prediction

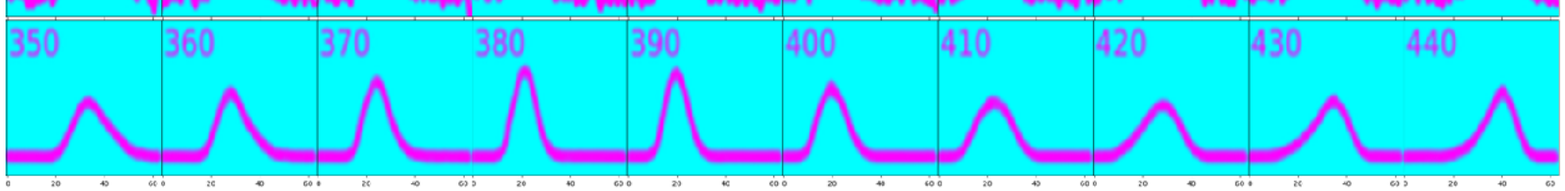

予測画像を生成できている。

mountain plotで見てみると

True_data:
ノイズ等を加える前の画像

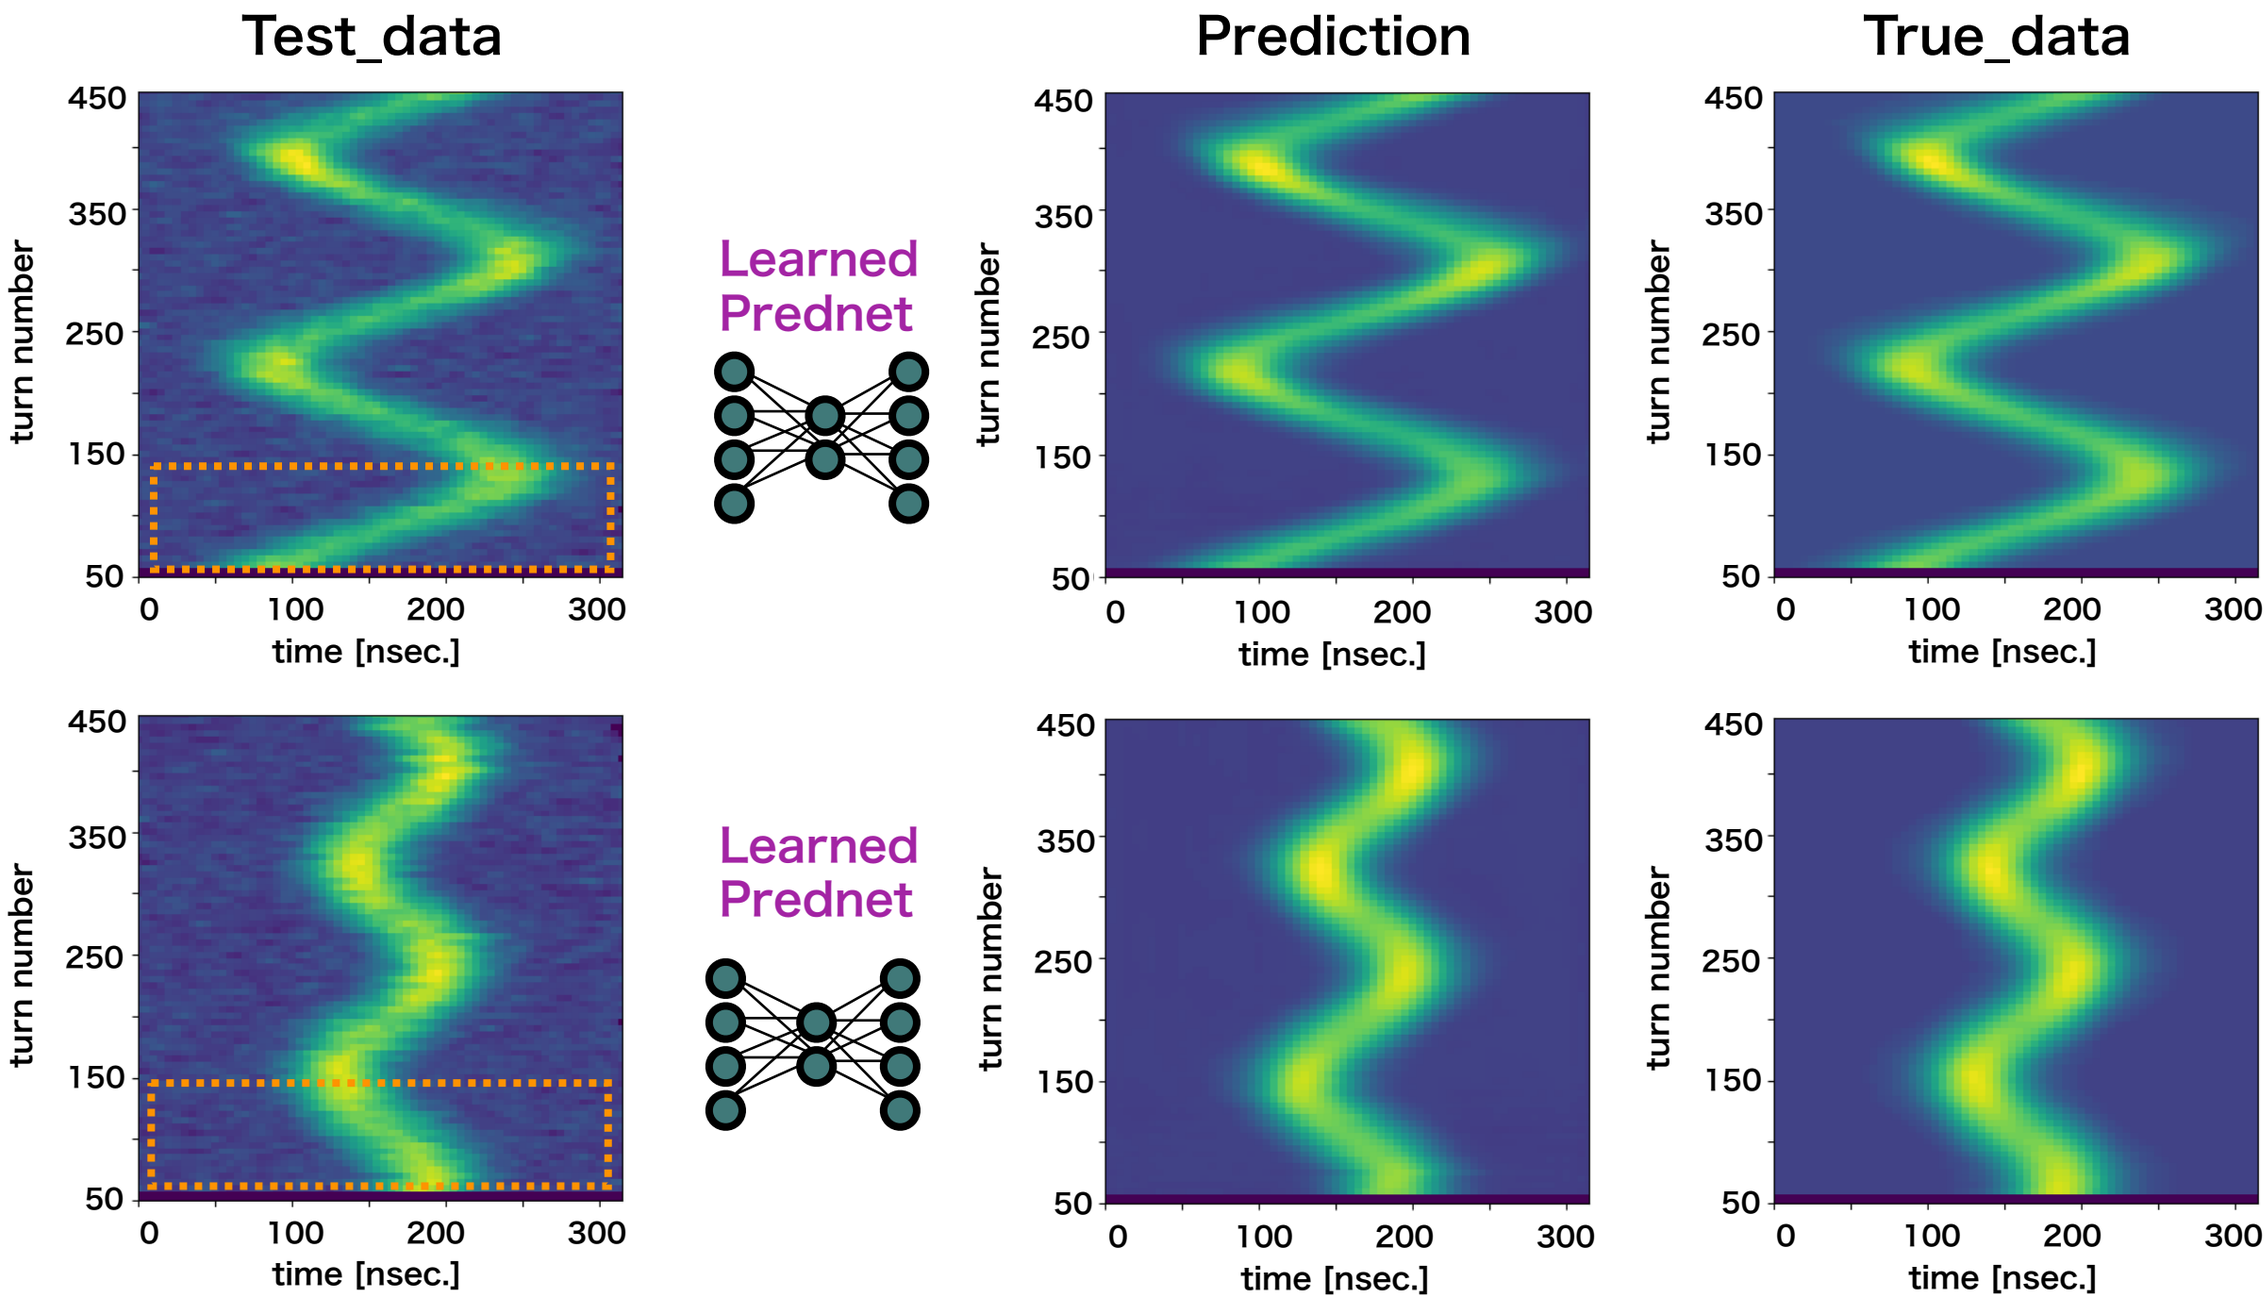

WCMの波形で見てみると、

Test_data + Prediction

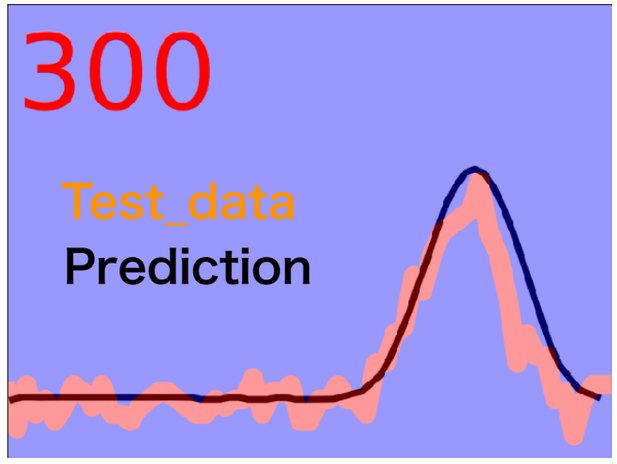

True_data + Prediction

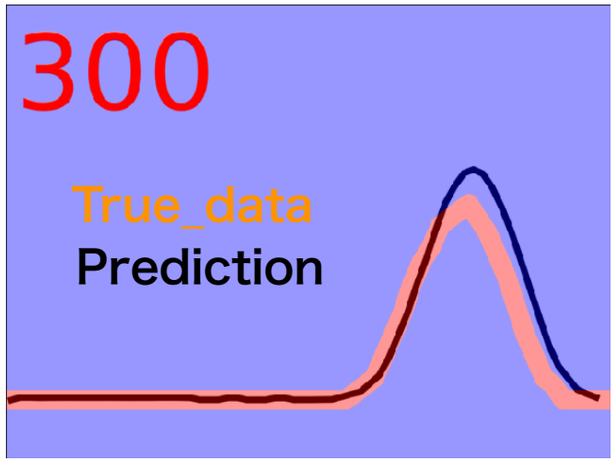

Test_data + Prediction

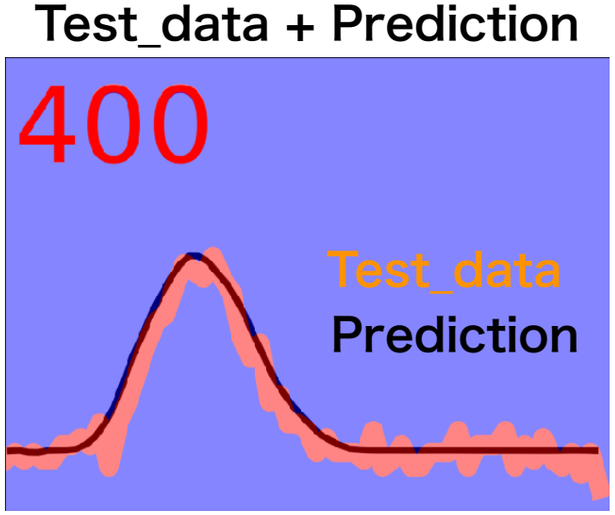

True_data + Prediction

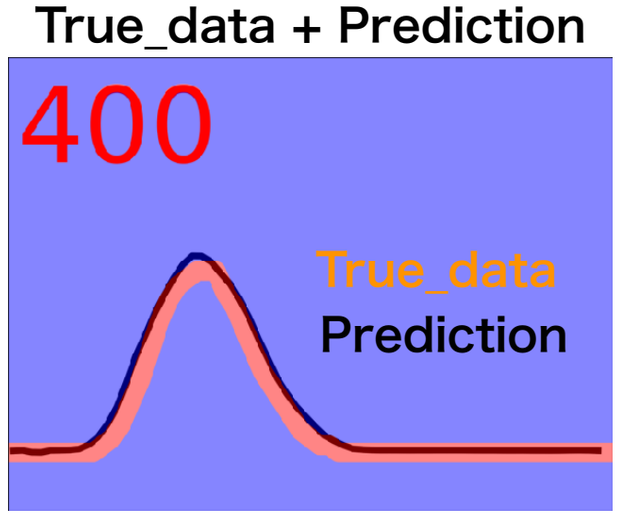

測定では、
　　同じ条件で数回測定し平均化することによりノイズ等の影響を取り除くことがある。

今回は、学習、つまり予測画像を正解画像に近づけることにより、
　　異なった条件でもノイズ等の影響を取り除くことができている。

450ターンまでの既知の領域では、予測画像は作成できた。

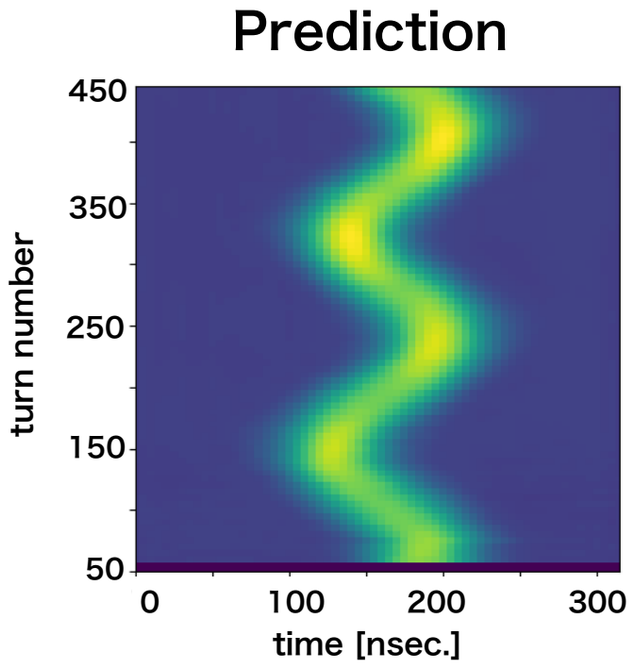

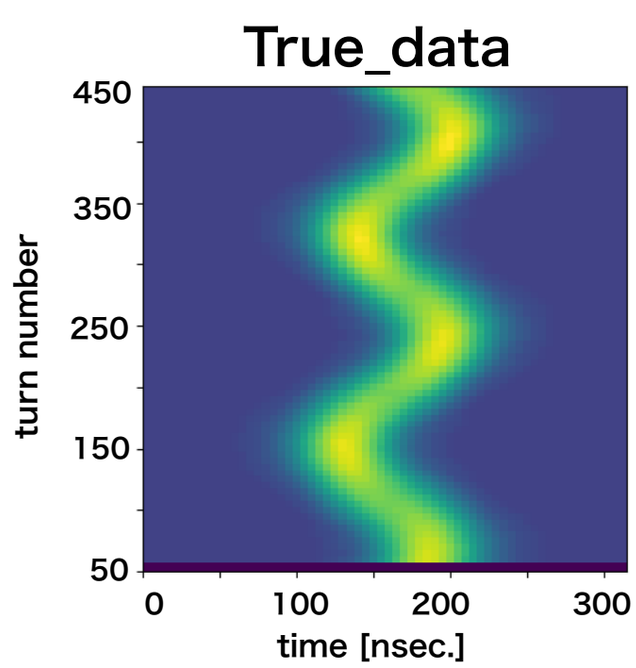

最も知りたいこと、それ以降の予測画像は正しく作成できるか？

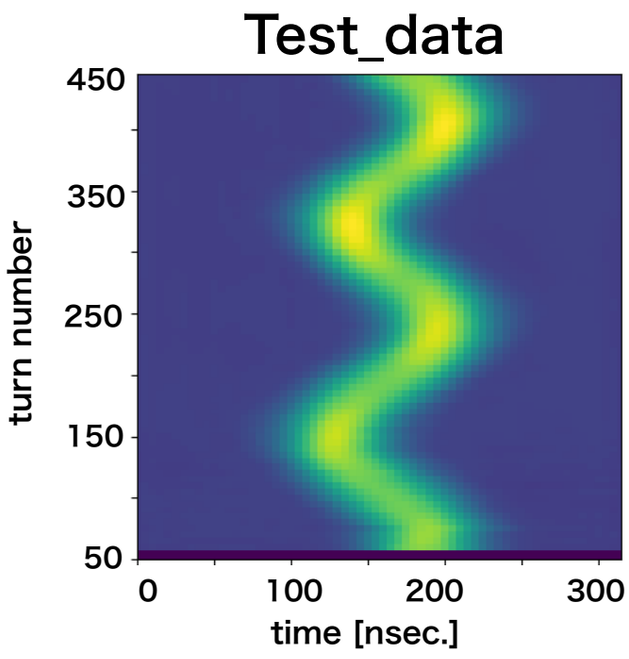

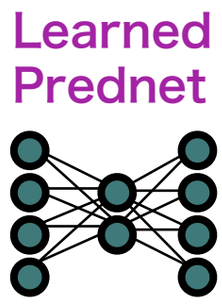

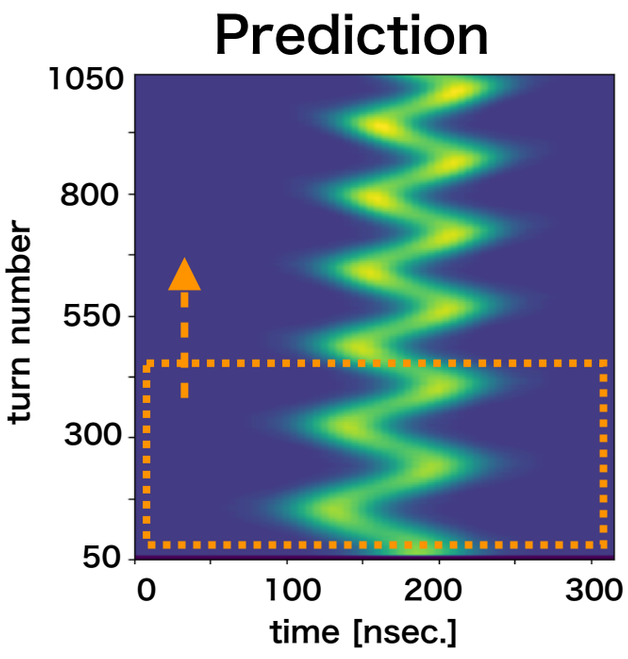

450ターン以降、1050ターンまでの予測画像を作成

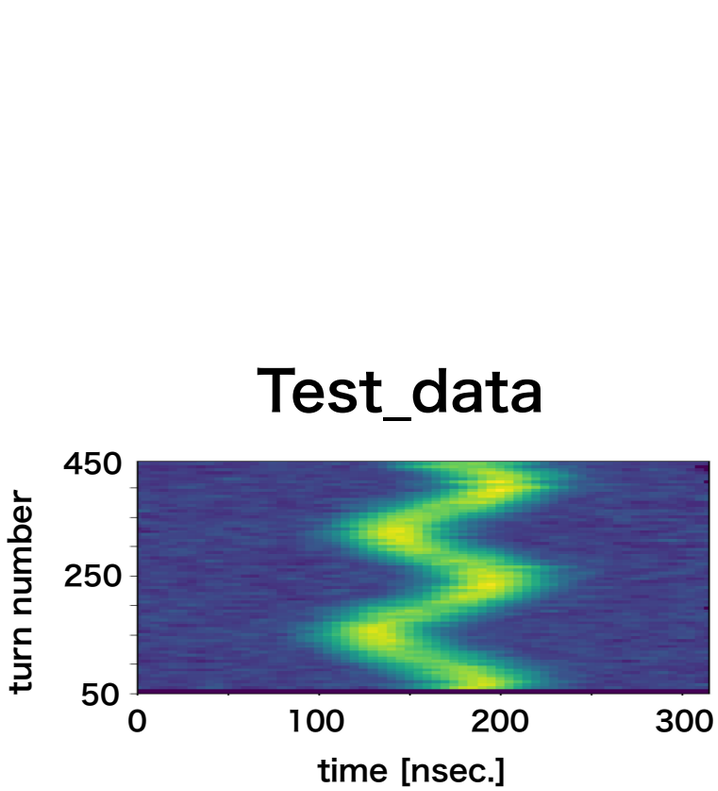

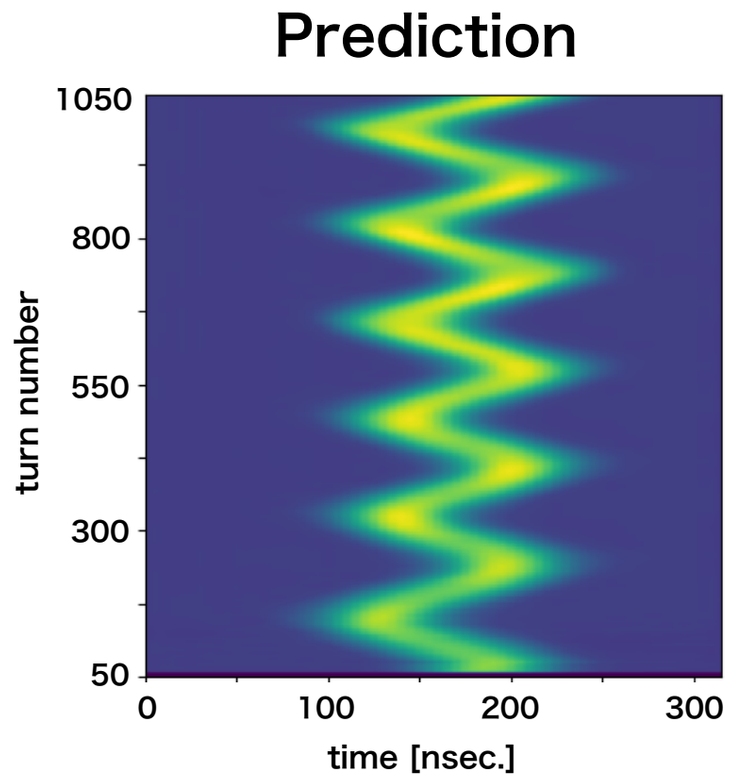

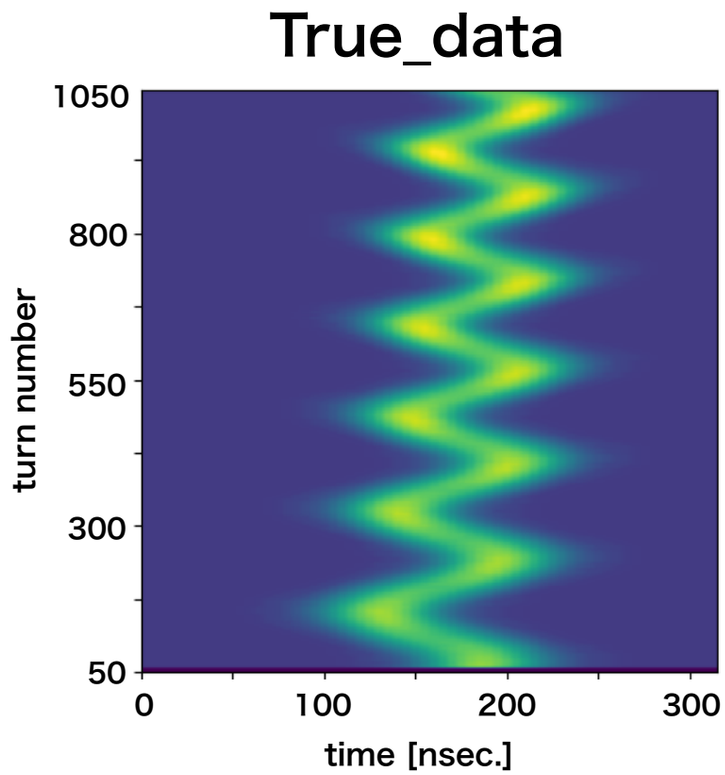

ターン後半では、予測値にズレ

加速条件は変化

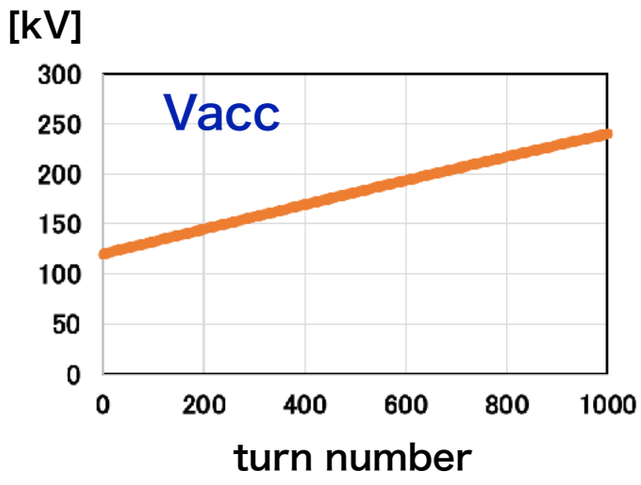

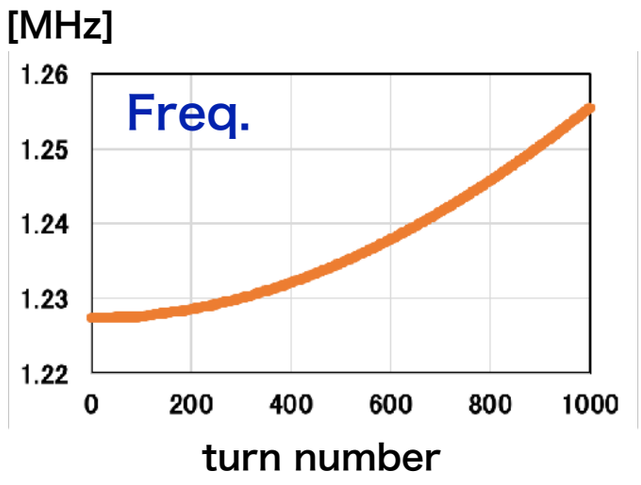

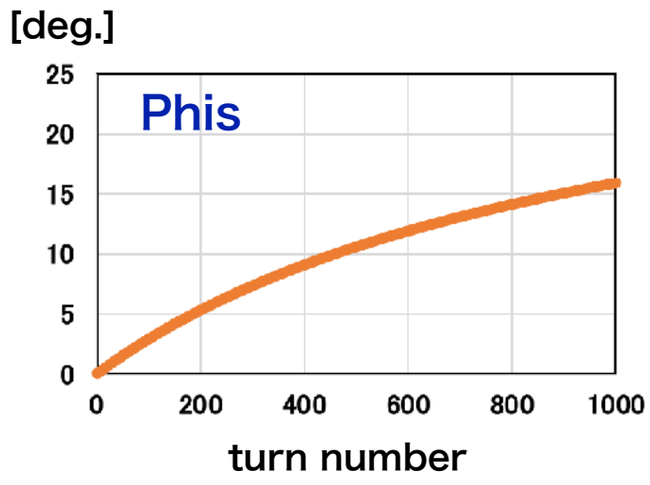

450ターンまでのWCMの波形の変化からでは、
それ以降を予測することはできない。

変化の小さい次の画像を逐次生成していくことは可能と思われる。
→ 教師データが必要。

予測できない領域(学習していない領域)では
信頼できる予測画像は作成できない。

予測したい場合はどうするか？　学習しか無い。

450ターンまでは学習出来ている。
そのモデルを使用すれば、
数少ない学習データ数でもいけるはず(fine_tuning)

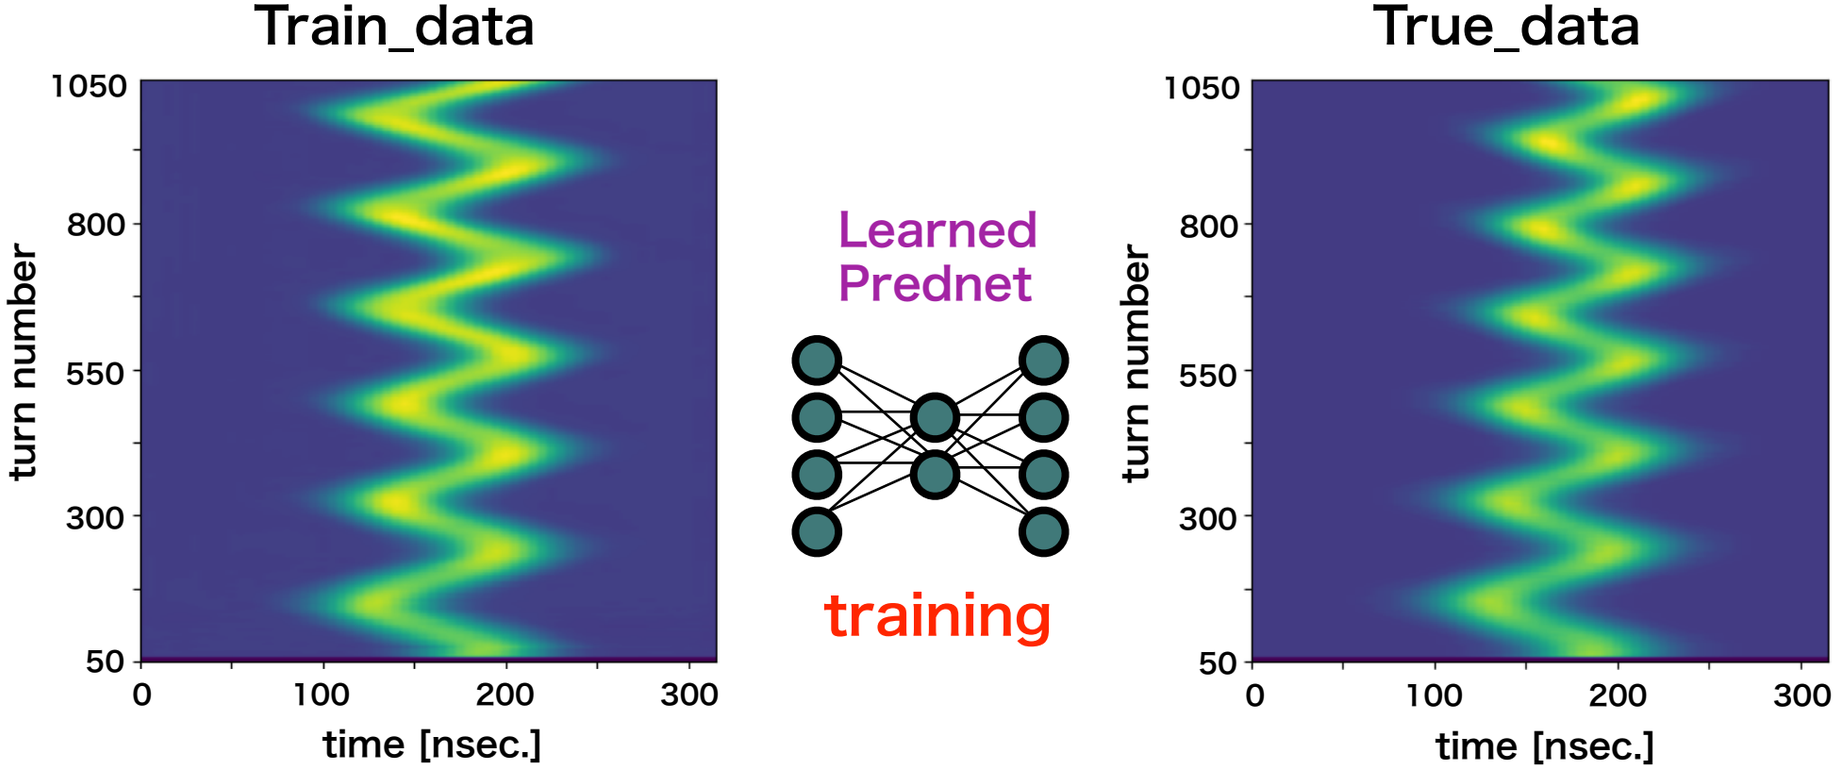

fine_tuningにはどれだけのデータ数が必要か？

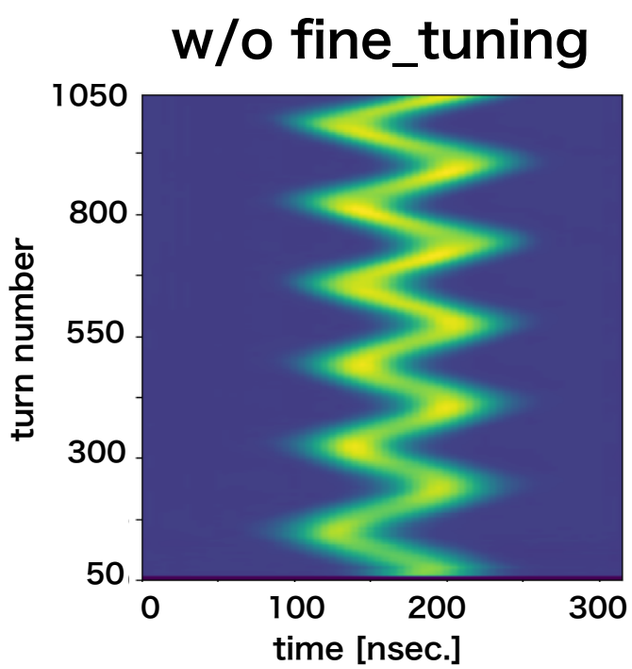

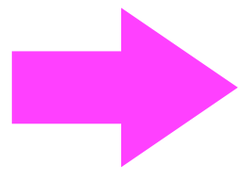

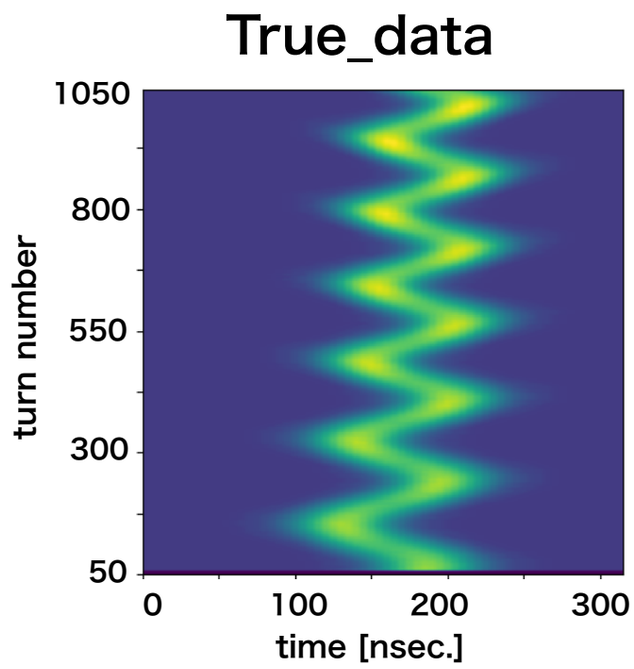

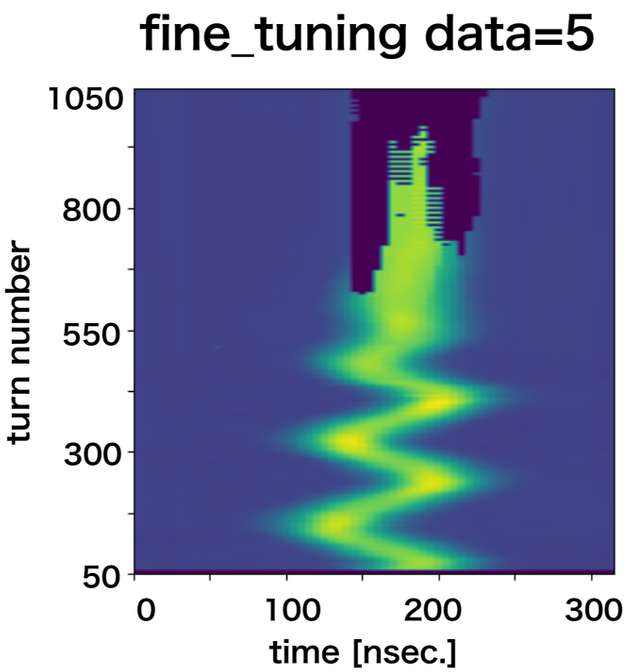

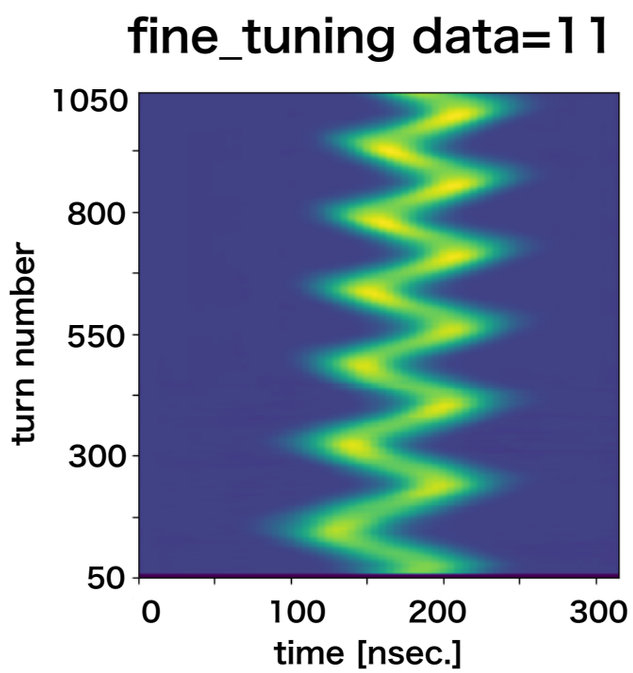

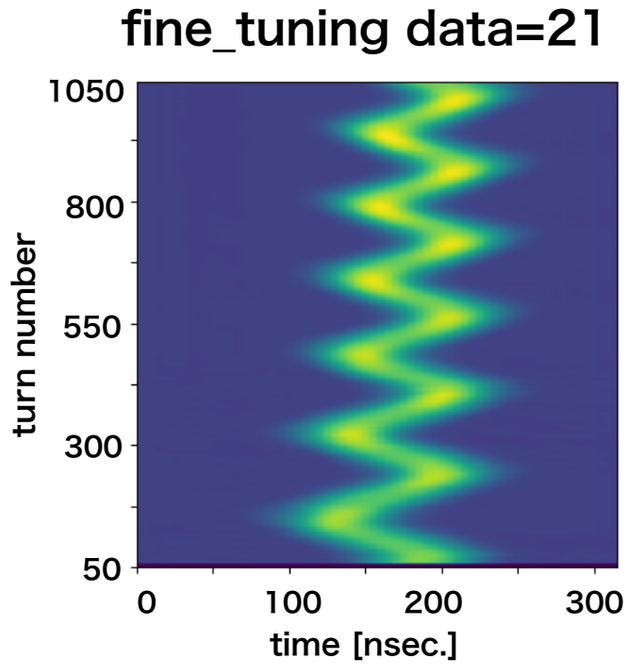

データ数11でのfine_tunigの結果

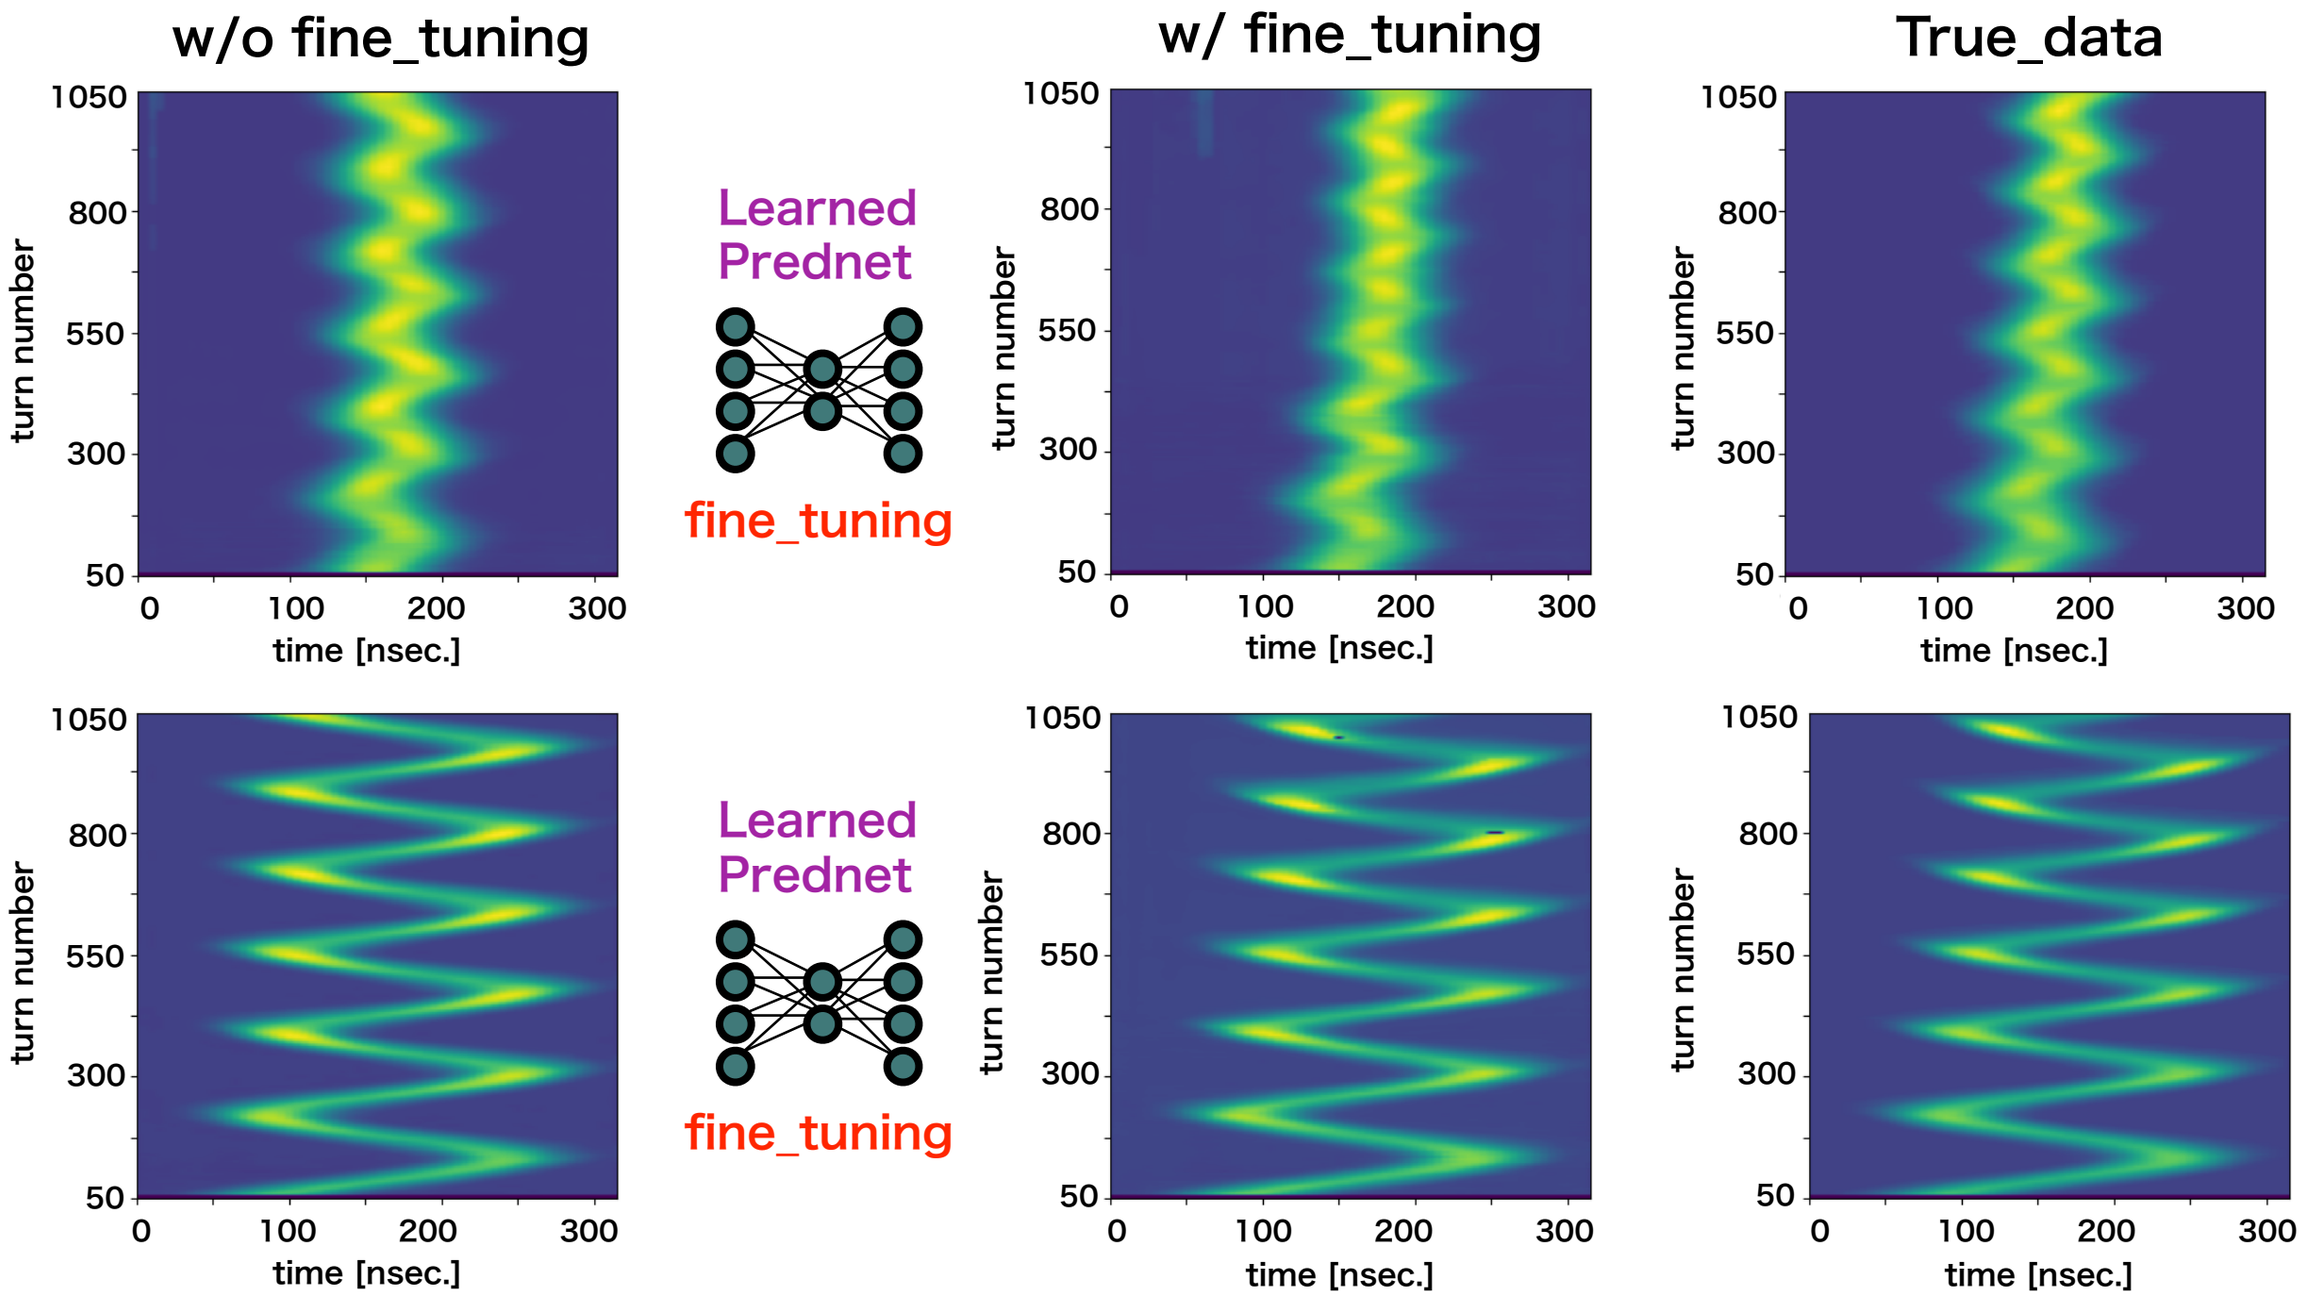

まとめ

PredNetで、
　WCMのターン毎の波形の変化を学習し、予測画像の作成を行った。

　　時系列の変化を学習させることで、
　　正解に近い予測画像を作成することができた。

予測画像を正解画像に近づけることにより、
　　ノイズ等の影響は取り除かれていた。

学習していない領域での予測は困難である。
変化の小さい次の画像を逐次生成していくことは可能と思われる。
　→ 教師データが必要。

fine_tunigは、有効な手段の一つと考えられる。

PredNet

William Lotter, Gabriel Kreiman & David Cox,
“DEEP PREDICTIVE CODING NETWORKS FOR VIDEO PREDICTION AND UNSUPERVISED LEARNING,”
arXiv:1605.08104, 2016.

pytorch

https://figshare.com/articles/software/Predictive_Coding_Deep_Neural_Network_in_PyTorch/16910767

Tensorflow(使用)

https://github.com/coxlab/prednet

mac studio (2020)

OS:Monterey
Apple M1 Max
10-Core CPU
24-Core GPU
16-Core Neural Engine
64GB unified memory

python	3.6.13
tensorflow	1.2.1
keras	2.0.6
hickle	2.1.0
h5py	2.10.0