

FROB04

**J-PARC**

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

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

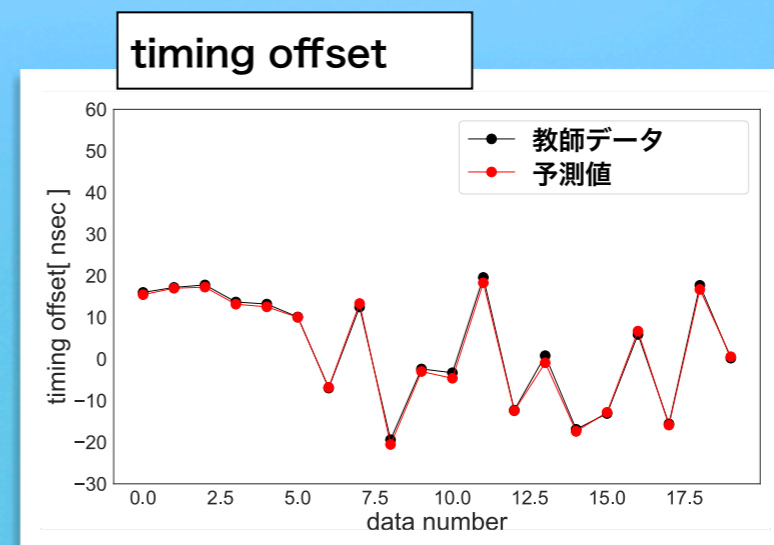
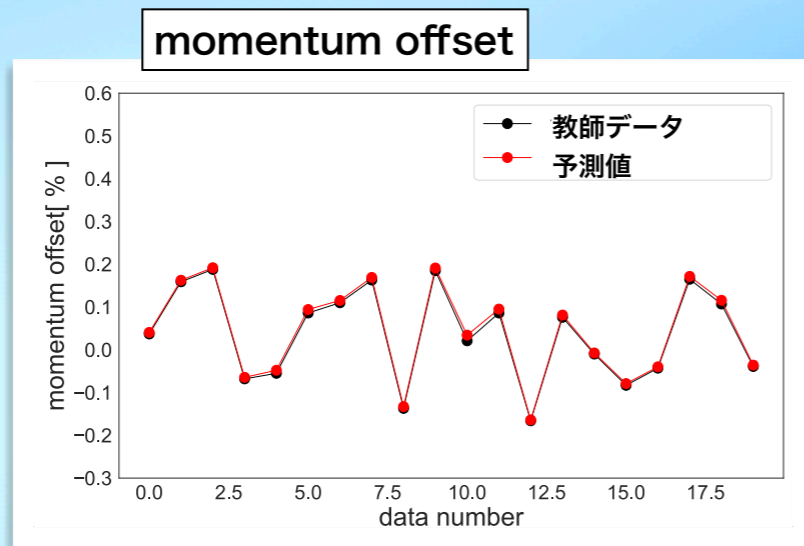

杉山 泰之, 原 圭吾, 長谷川 豪志, 大森 千広, 吉井 正人  
(高エネルギー加速器研究機構 J-PARC)

第19回日本加速器学会年会

# 現状では、


CNN : Convolutional Neural Network

J-PARC RCS では、畳み込みニューラルネットワーク(CNN)により、マウンテンプロットの画像から、調整時に必要な入射ビームの情報が得られる様にしている。





# 入射ビームの情報を得られてはいるが、



運動量オフセット、タイミングオフセットは  
人でも比較的容易に求まる。

画像認識で行う必要があるか？

機械学習でもできますよ、では無く

人では困難な情報(運動量広がり、時間構造)を、  
画像認識技術によって求めてみたい

運動量広がり：ガウス分布を仮定して標準偏差 $\sigma$

時間構造：強度一定として時間幅 $W$


それぞれの値では無く、

位相空間上での分布として求められることが望まれる。

# 本研究では、

マウンテンプロット画像から、CNNにより  
入射ビームの情報を位相空間上での分布を画像として求めてみる

測定した画像から物理量を求める、CNNを解析手段の一つとして利用



CNN：出力を値から画像に変更、TensorFlow を使用

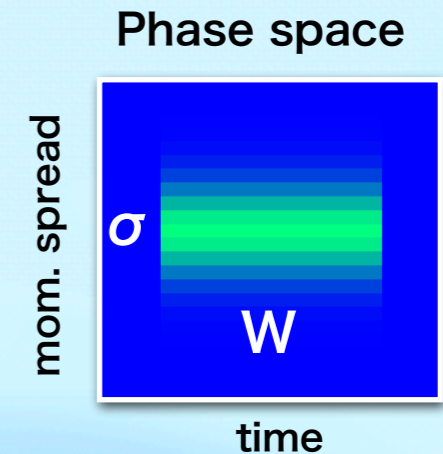
入力と出力の画像の作成が主



# まずは、今まで行ってきた単純な分布で検証


位相空間上での分布：

運動量広がり は ガウス分布の標準偏差  $\sigma$ 、  
縦方向についてはビーム強度は一定として時間幅  $W$ 、



Mountain plot：

位相空間上の分布に従って作られた粒子を初期条件として、  
シミュレーションにより作成。



RCSへの入射調整時のビーム条件を考慮し画像を作成。

マルチターン入射：30ターン

運動量広がり  $\sigma = 0.07 \sim 0.13$  [%]、時間幅  $W = 70 \sim 110$  [nsec]

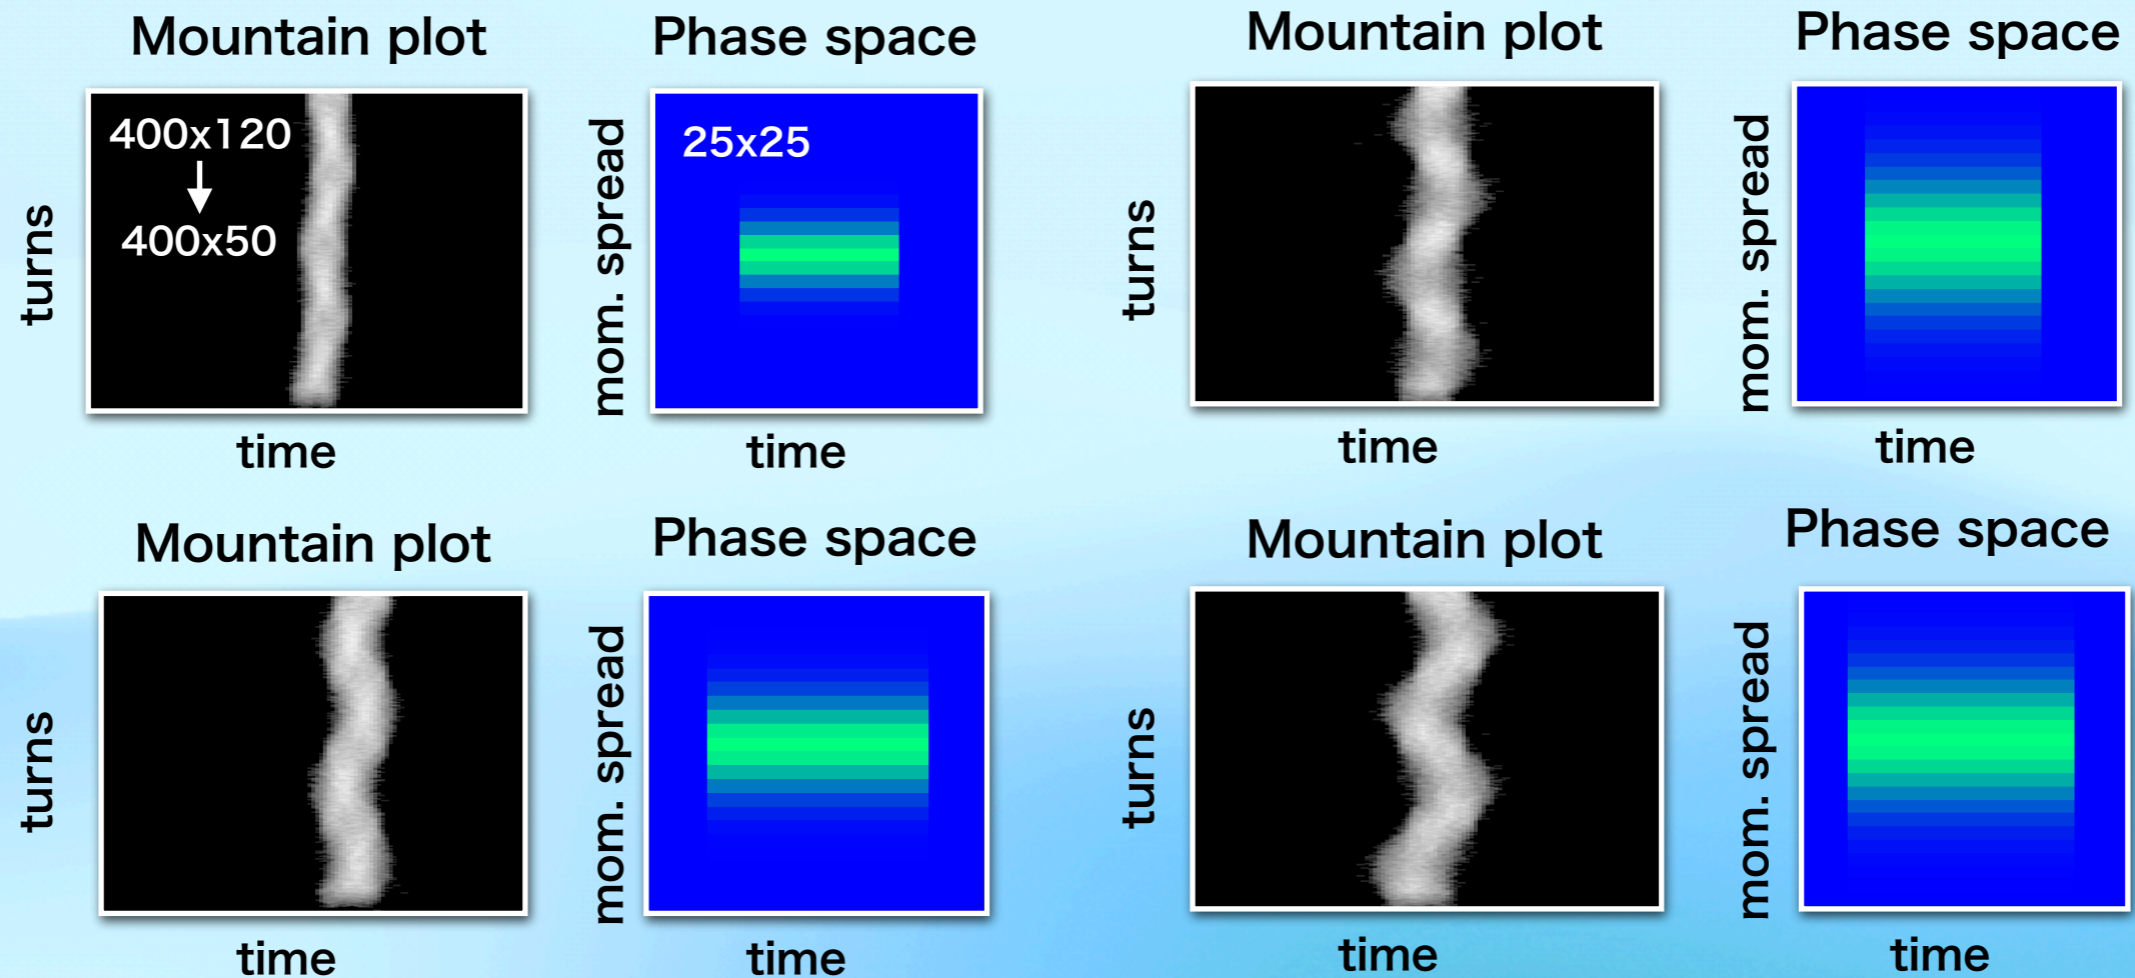
運動量オフセット =  $-0.1 \sim +0.1$  [%]、タイミングオフセット =  $-10 \sim +10$  [nsec]

← 求める値

← 外乱

乱数により範囲内の値を発生させ画像を作成


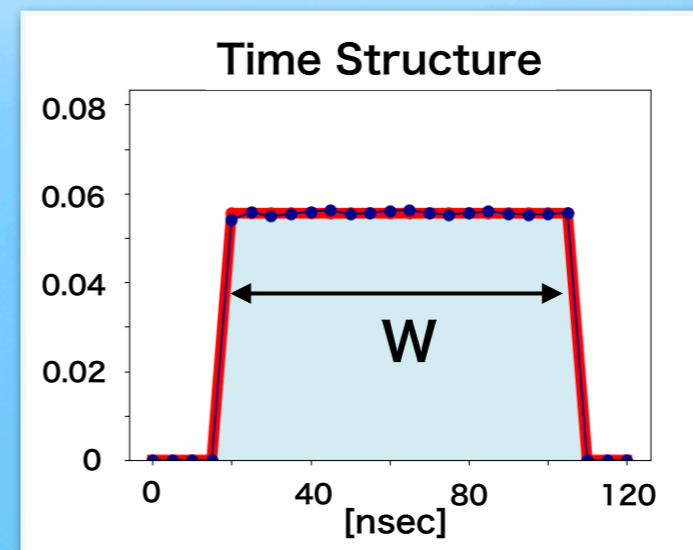

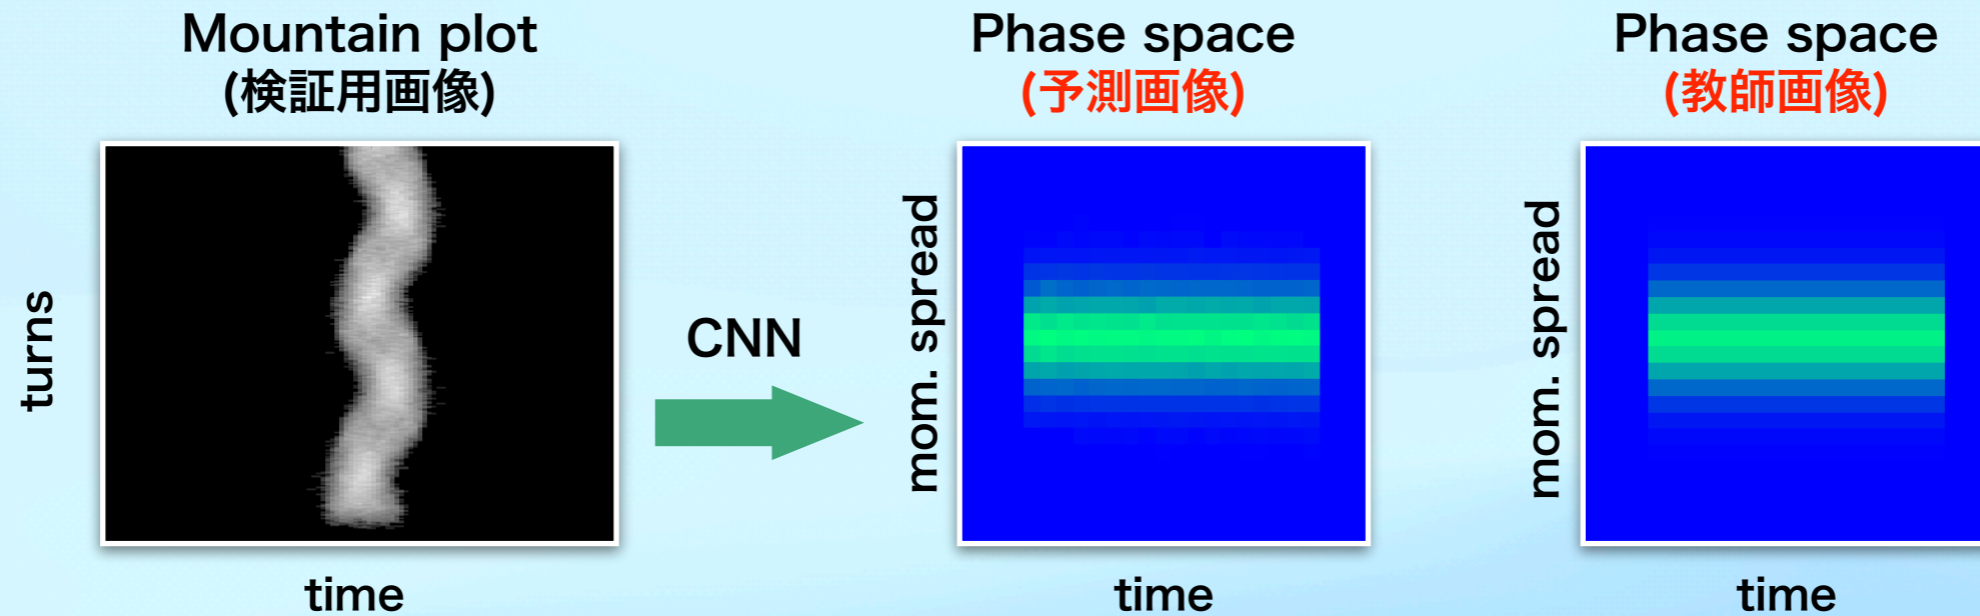
# 画像5000組 (学習用画像4500組, 検証用画像500組)



**Mountain plot**を入力画像として、  
**CNN**による予測画像が**Phase space**の画像となる様に学習。



# 学習したCNNによる予測結果



以前と同様に、求まることが確かめられた。


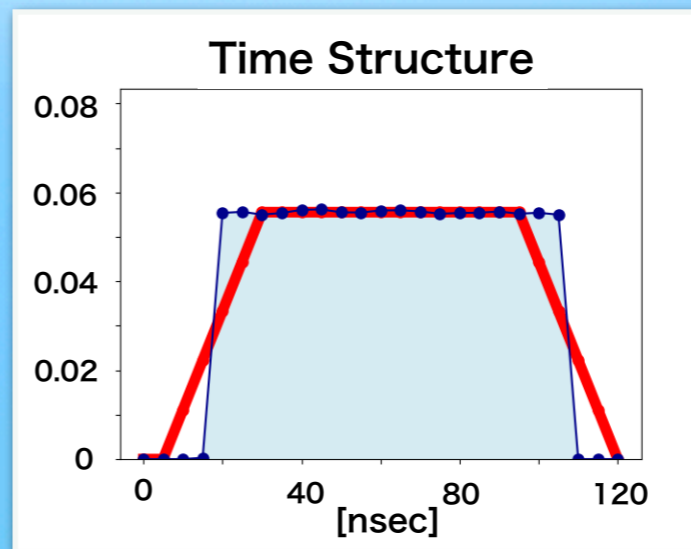
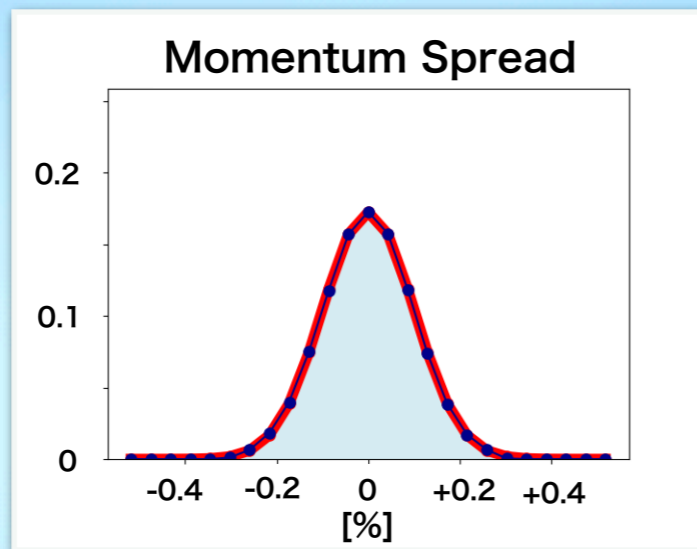

これで位相空間上での分布を再現できる訳ではない

学習していない分布は  
正しく再現することはできない。

学習していない分布、  
立ち上がり、立ち下がりが傾きを持った場合を予測してみる




# 学習していない分布の予測結果







学習した画像で近似

# 学習していない画像は再現できない

あらゆる画像を全て、学習させることは不可能



位相空間上でどのような分布かを考察し、  
そ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

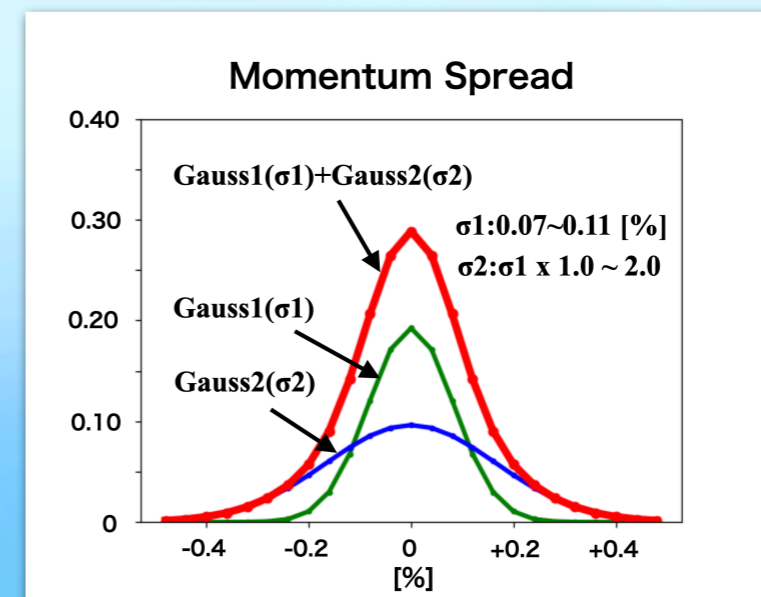
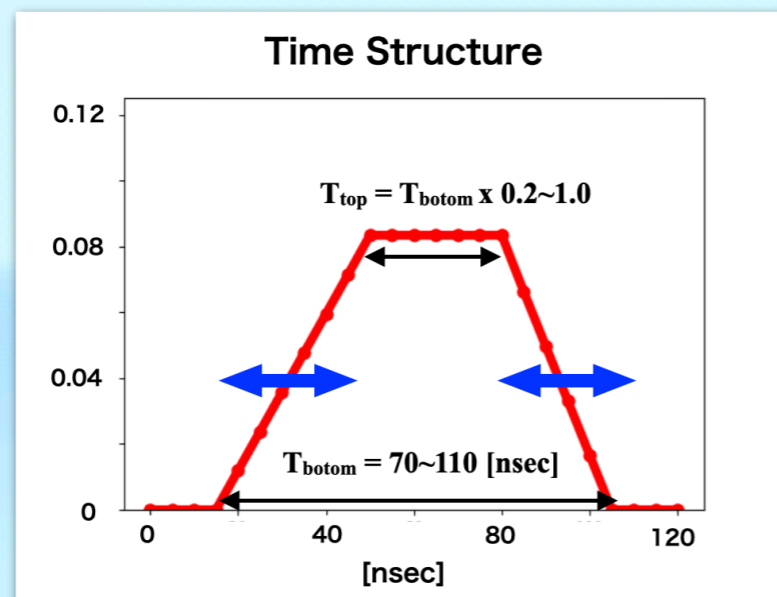




# 現実的な位相空間上での分布の予測

## 現実的な位相空間上での分布

時間構造：立ち上がり立ち下りに傾き  
運動量広がり：テールを引く

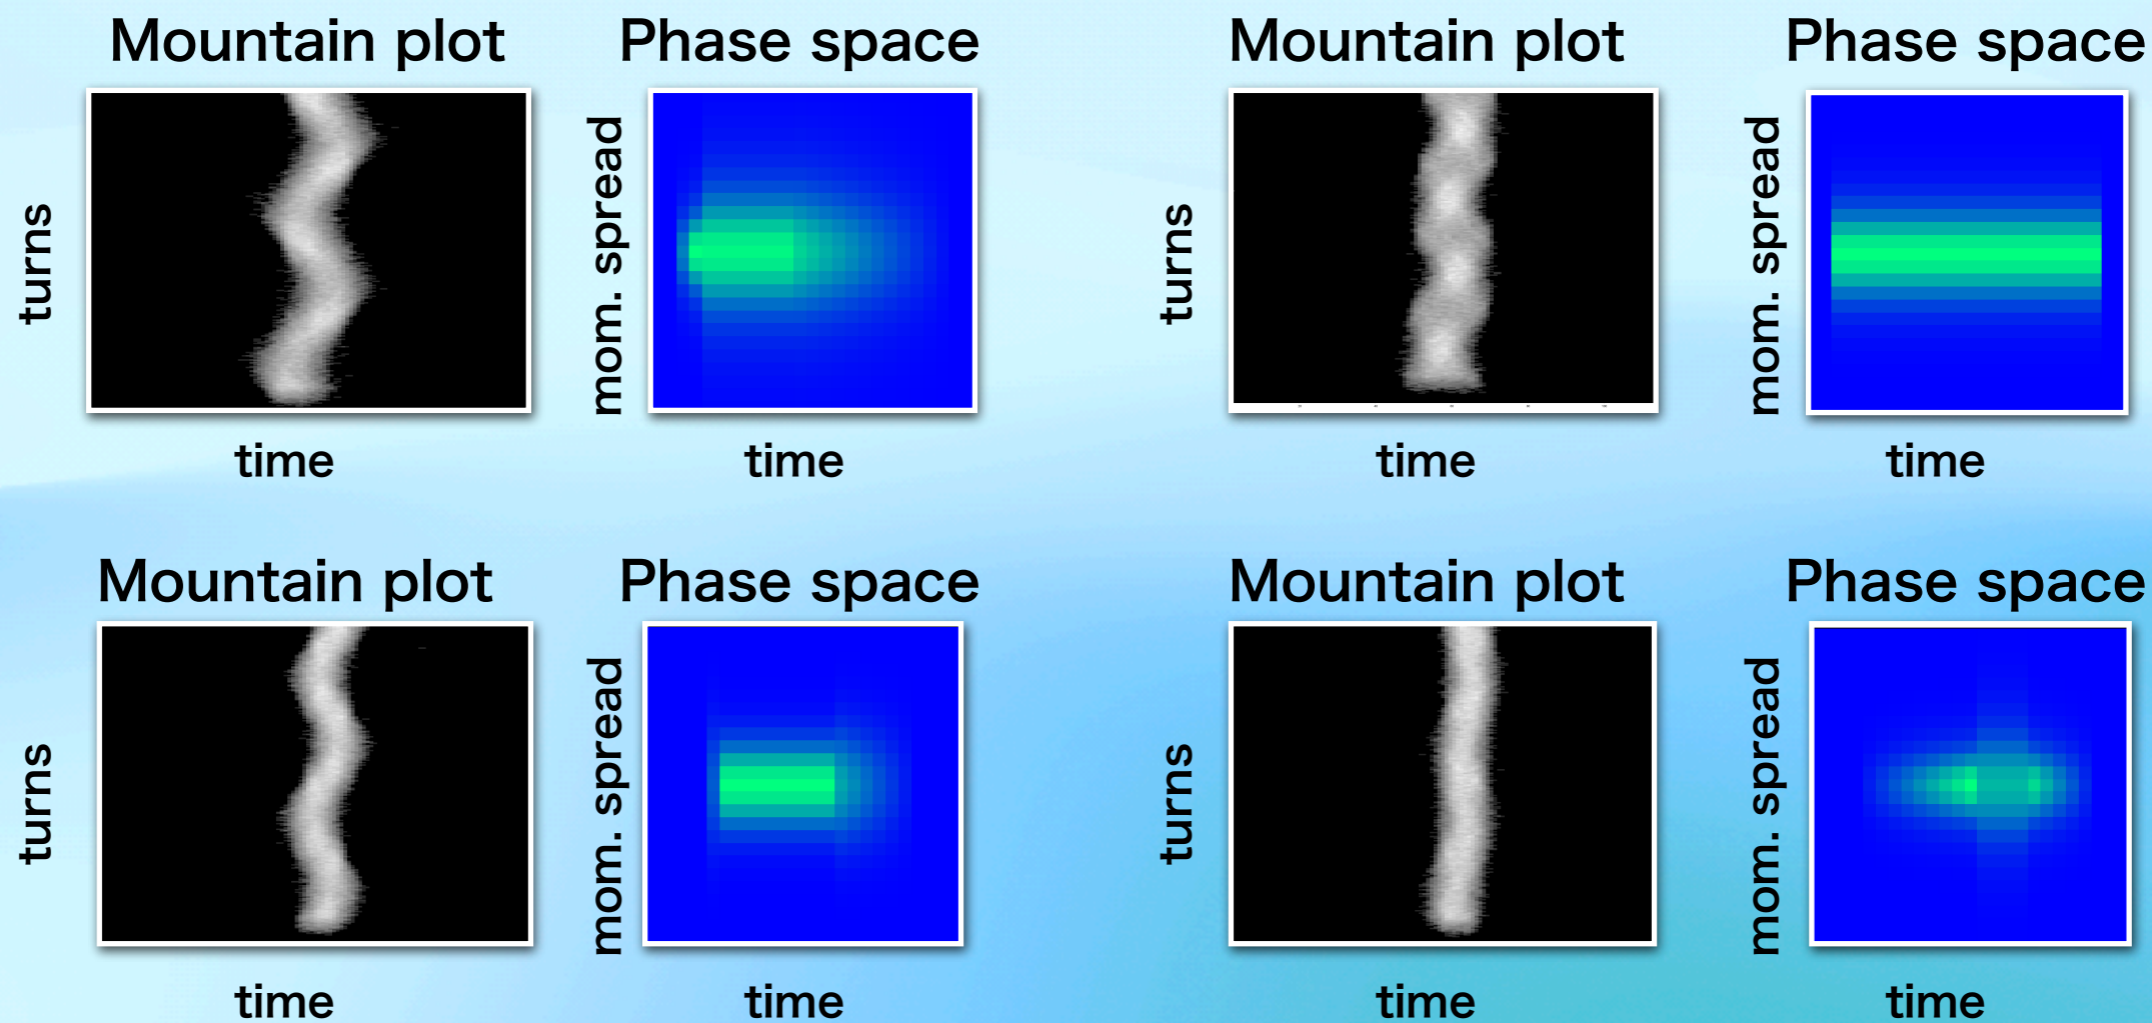


## 運動量広がり時間が時間と相関がある場合：画像としてのメリット

立ち上がり、フラット部、立ち下がり：運動量広がりが違う

立ち上がり立ち下がり部分の運動量広がり = 中央のフラット部  $\times 0.6 \sim 1.4$ 倍


# 画像50000組 (学習用画像45000組, 検証用画像5000組)



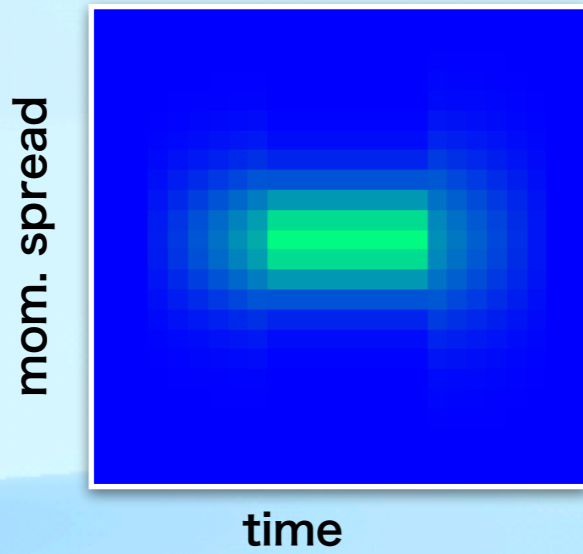
これらの学習用画像を学習し、CNNにより予測




# 学習後のCNNによる予測結果



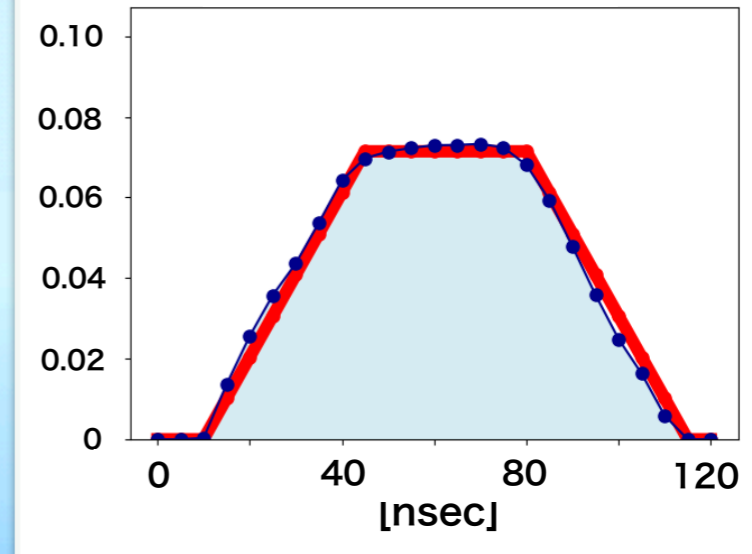
Phase Space  
(教師画像)




Phase Space  
(予測画像)




Time Structure



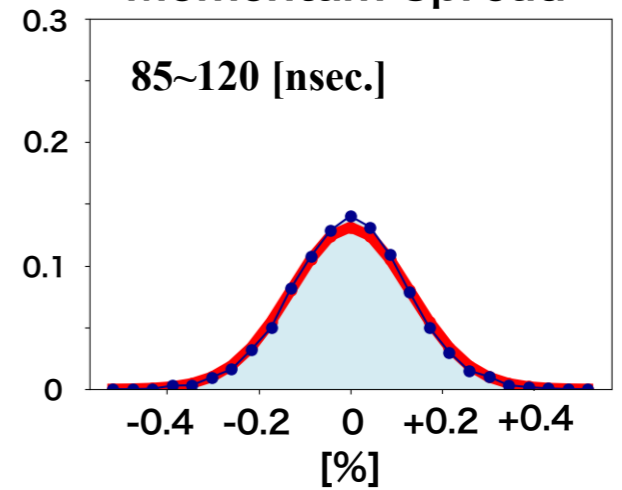
Momentum Spread



Momentum Spread



Momentum Spread




**この程度の複雑さの分布でも、  
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**



CNNによる画像認識は、  
どこまで細かく画像を認識しているか

Mountain plot: **A**


turns



time


Mountain plot: **B**

turns




time

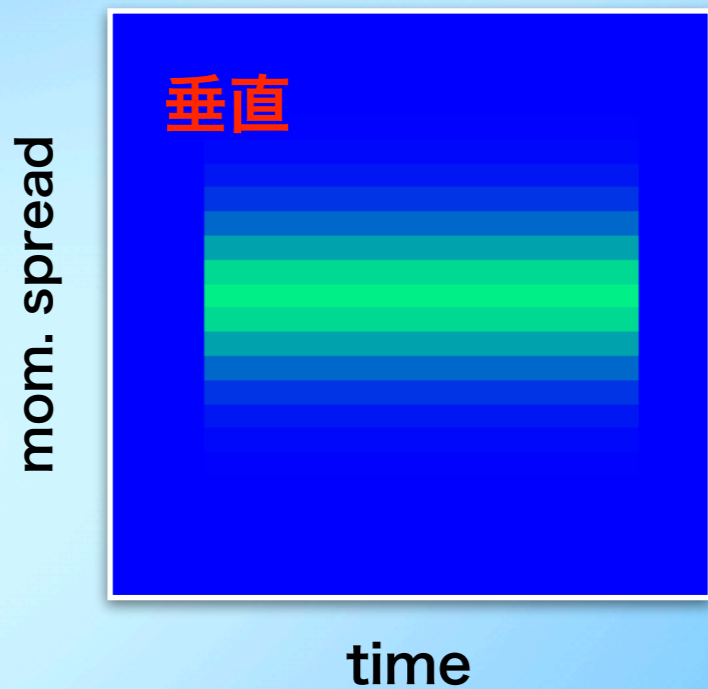
Mountain plot: **A**



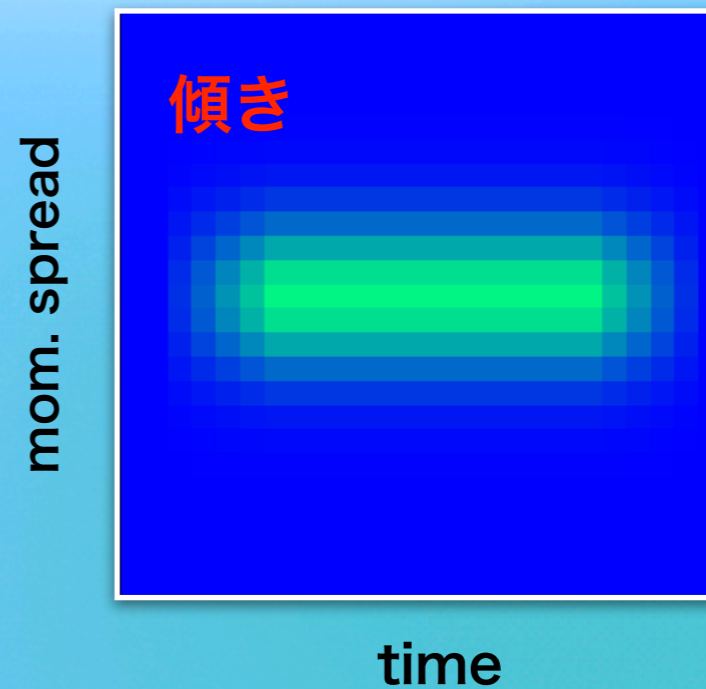
Mountain plot: **B**



Phase space: **A**




Phase space: **B**

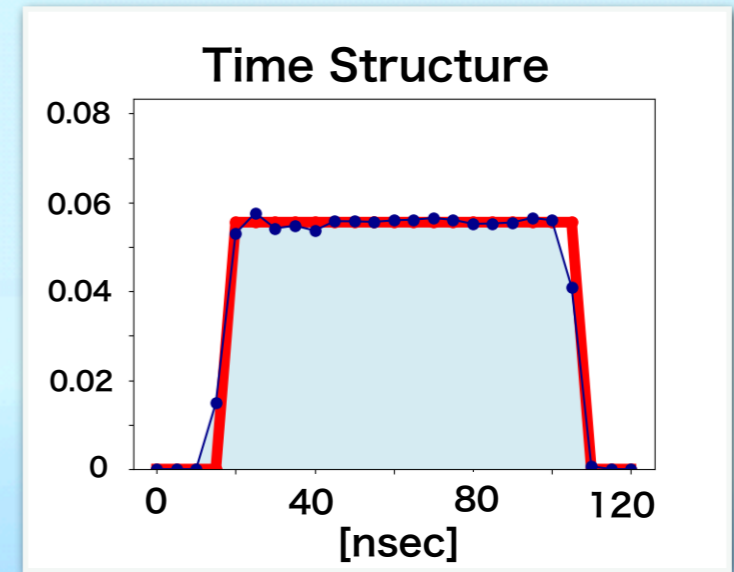









# 先ほどの学習済みCNNによる予測結果



予測画像: **A**



予測画像: **B**



# まとめ

CNNの画像認識により、  
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。

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のできる学習用画像を準備することが必要。

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。

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。