Machine learning action parameters in lattice quantum chromodynamics

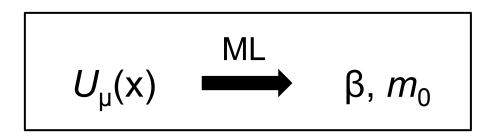
Reference

PRD97, 094506 (2018) [arXiv:1801.05784]

大野浩史 文献紹介 2018年6月8日

概要

機械学習を用いて、ゲージ配位から作用のパラメータを予想する。



入力するデータを工夫するとある程度うまくいく。

シミュレーションセットアップ

- $N_c = 2$ Wilson gauge
- $N_f = 2$ dynamical Wilson quarks
- 最初の 500 trajectory を除き 10000 trajectory まで 10 trajectory ごとの保存 = 950 配位
- Grid A: 12³x36, 20パラメータ
- Grid B: 12³x36, 25パラメータ
- Grid C: 16³x36, Grid A と同じパラメータ
- Set D & E: 同じプラケット値を持つパラメータセット
- Set F: パラメータの同じ10個の独立なアンサンブル

そもそもゲージ配位の見分けがつくのか?

- 主成分分析で確認
- ウィルソンループの相関関数

/; = 1x1, 1x2…: ループの種類

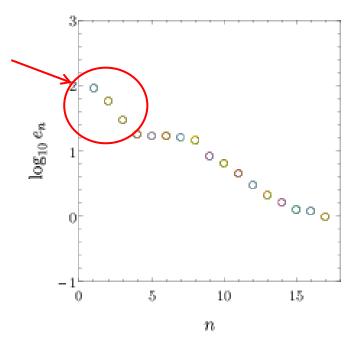
e: アンサンブル

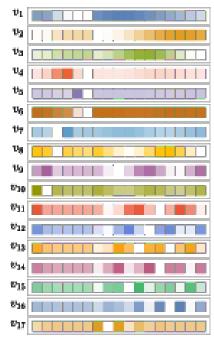
c: 配位

$$\mathcal{M}_{\ell_i,\ell_j} = \sum_{e} \sum_{c} \frac{\left[W_{\ell_i}(e,c) - \overline{W}_{\ell_i}(e) \right] \left[W_{\ell_j}(e,c) - \overline{W}_{\ell_j}(e) \right]}{\sigma(W_{\ell_i}(e))\sigma(W_{\ell_j}(e))}$$

Grid A

支配的な3固有値





そもそもゲージ配位の見分けがつくのか?

- 主成分分析で確認
- ウィルソンループの相関関数

/_i = 1x1, 1x2...: ループの種類

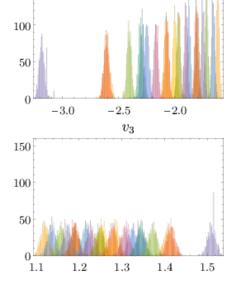
e: アンサンブル

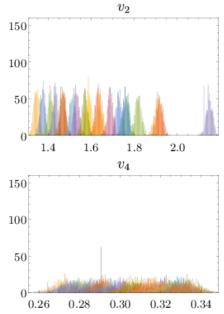
c: 配位

$$\mathcal{M}_{\ell_i,\ell_j} = \sum_e \sum_c \frac{\left[W_{\ell_i}(e,c) - \overline{W}_{\ell_i}(e)\right] \left[W_{\ell_j}(e,c) - \overline{W}_{\ell_j}(e)\right]}{\sigma(W_{\ell_i}(e))\sigma(W_{\ell_j}(e))}$$

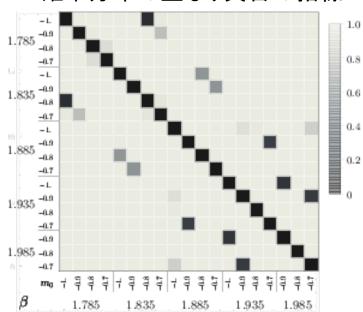
Grid A

150





Jensen-Shannon divergence = 確率分布の重なり具合の指標



そもそもゲージ配位の見分けがつくのか?

- 主成分分析で確認
- ウィルソンループの相関関数

/; = 1x1, 1x2...: ループの種類

e: アンサンブル

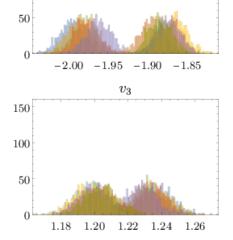
c: 配位

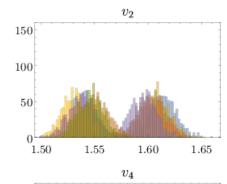
$$\mathcal{M}_{\ell_i,\ell_j} = \sum_e \sum_c \frac{\left[W_{\ell_i}(e,c) - \overline{W}_{\ell_i}(e)\right] \left[W_{\ell_j}(e,c) - \overline{W}_{\ell_j}(e)\right]}{\sigma(W_{\ell_i}(e))\sigma(W_{\ell_j}(e))}$$

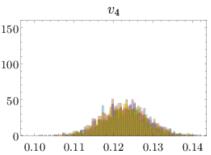
Set D&E

150

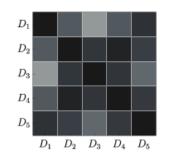
100

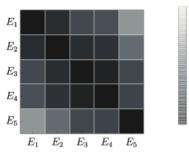






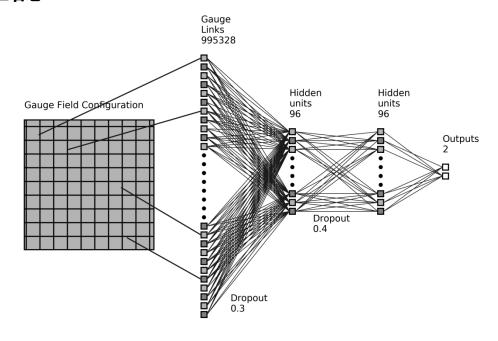
Jensen-Shannon divergence = 確率分布の重なり具合の指標



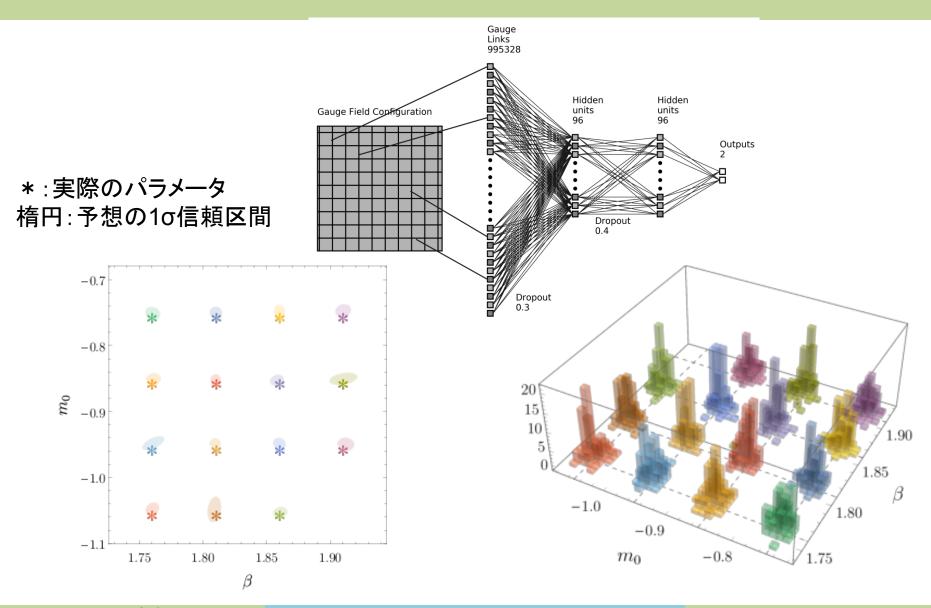


機械学習

- 多層パーセプトロン
 - 3層以上、全結合
 - 非線形活性化関数(tanh等)
- ランダムに選んだ850配位で学習、残りの100配位で予想の精度を確認



ゲージ配位そのものを入力にした場合



ゲージ配位そのものを入力にした場合

- 一見うまくいっているように見える
- 実際にはうまくいっていない(予想が一般化できない)
 - Set F からは学習に用いたすべてのパラメータの平均が得られる
 - 学習に用いた配位から連続的に生成された配位を入力した時、trajectory数が増えるほど正しい値からずれて、平均値へ近づく

• 原因

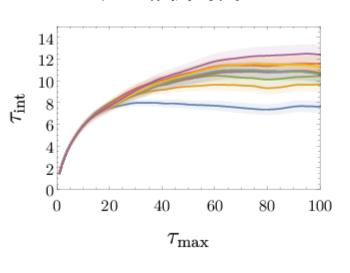
- ゲージ配位の自由度に対して、学習データ(配位数)が少な すぎる
- 物理とは関係のない長相関の特徴にとらわれている

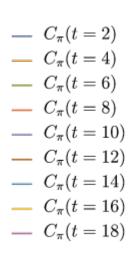
ゲージ配位そのものを入力にした場合

- Set Fを用いて長相関を検証
- 2つのアンサンブルペアを見分けられる確率を推定
- →自己相関関数

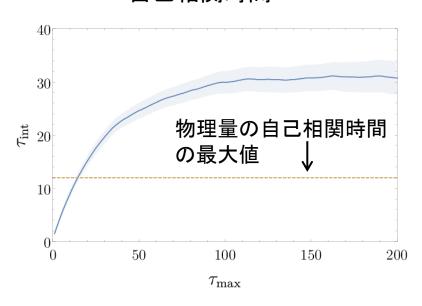
$$\rho(\tau) = 2 \left[P_{\alpha} \left(c^{\alpha}(\tau) \right) + P_{\beta} \left(c^{\beta}(\tau) \right) \right] - 1$$

π中間子相関関数 の自己相関時間



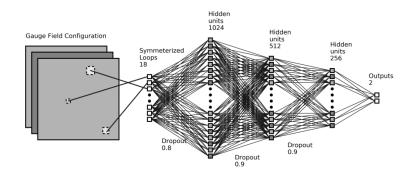


機械学習に現れる自己相関時間



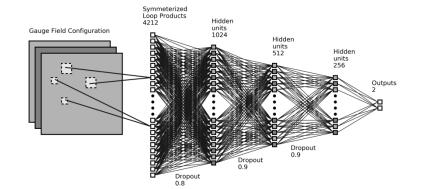
ウィルソンループを入力にした場合

SL



ウイルソンループそのもの (nxn, 1xn のみ)

CP



ウイルソンループ同士の相関

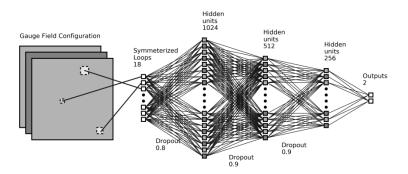
$$W_{j \times k, l \times m}(R) = \sum_{|r|=R} \sum_{\ell \in \mathcal{O}(j \times k)} \sum_{\ell' \in \mathcal{O}(l \times m)} \sum_{x} W_{\ell}(x) W_{\ell'}(x+r)$$

両方

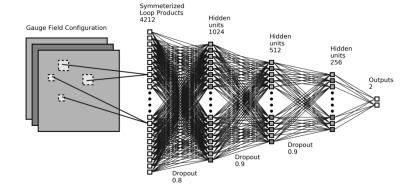
$$\mathcal{W}_{j \times k, l \times m}^{\text{(sub)}}(R) = \sum_{|r|=R} \sum_{\ell \in \mathcal{O}(j \times k)} \sum_{\ell' \in \mathcal{O}(l \times m)} \left[\sum_{x} \mathcal{W}_{\ell}(x) \mathcal{W}_{\ell'}(x+r) - \sum_{x} \mathcal{W}_{\ell}(x) \sum_{x} \mathcal{W}_{\ell'}(x) \right]$$

ウィルソンループを入力にした場合

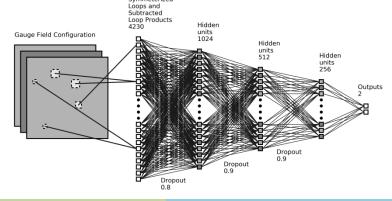


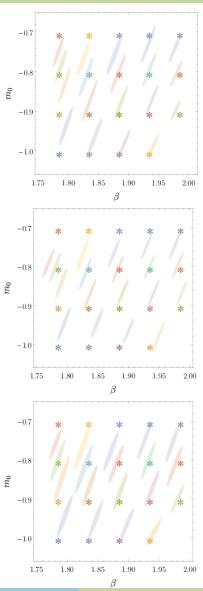


CP

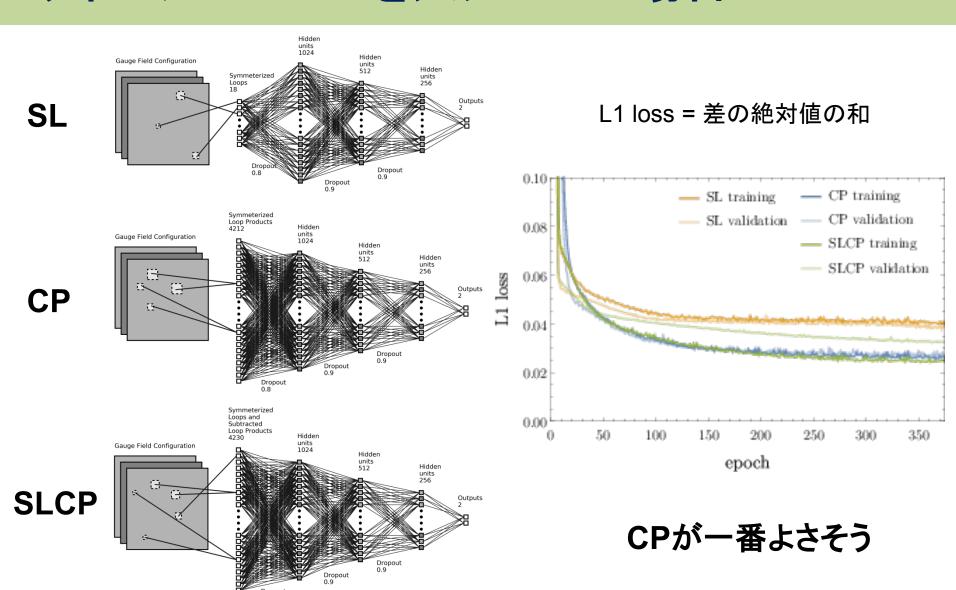


SLCP

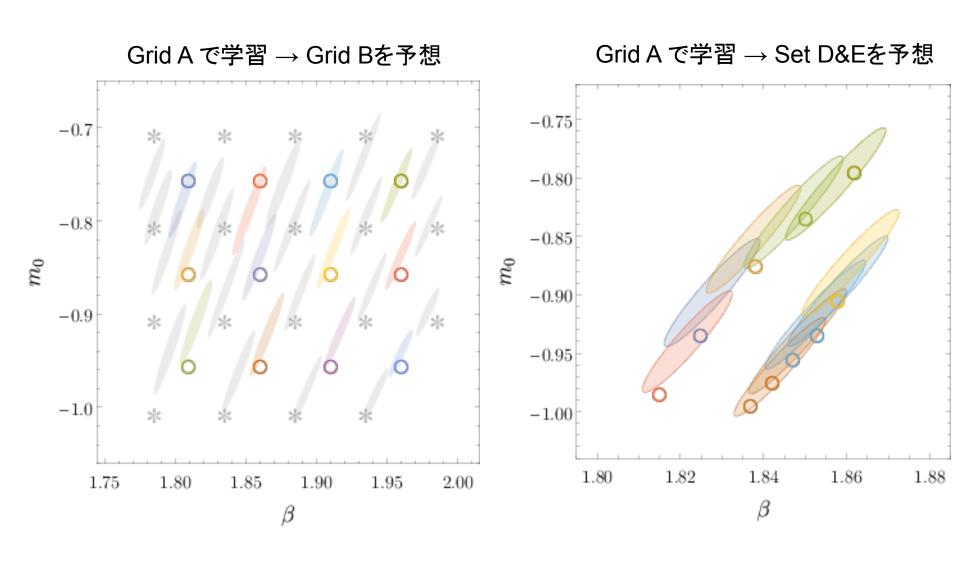




ウィルソンループを入力にした場合

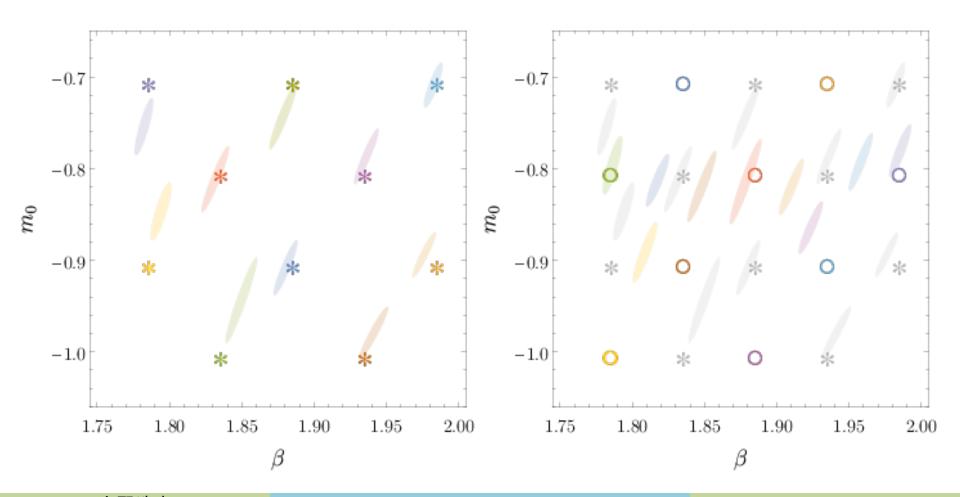


CPを用いた予想



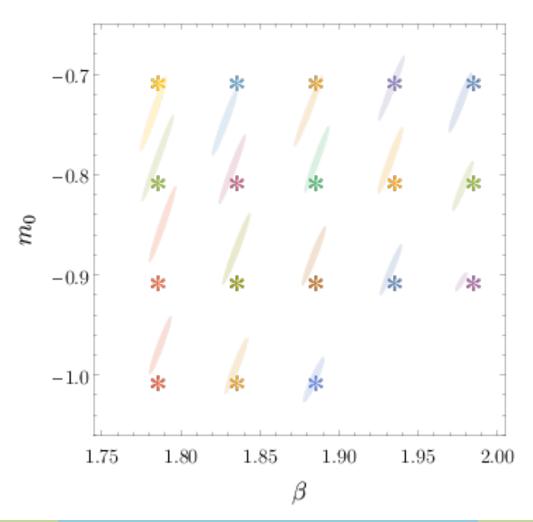
CPを用いた予想

Grid Aで学習 → Grid B を予想 (パラメータの間隔が広い場合)



CPを用いた予想

Grid C(より体積が大きい場合)



まとめ

入力を工夫すると、機械学習を用いてゲージ配位から 作用のパラメータをある程度予想することができる

• 疑問

- 学習データを用意する手間と、得られる結果が本当につりあ うのか?
- 既存の方法より、優れているのか?