

Towards reduction of autocorrelation in HMC by machine learning



CCNU → 理研(和光) → 理研(ブルックヘブン)

富谷 昭夫

共同研究者: 田中章詞 (理化学研究所 革新知能統合研究センター)

Based on arXiv:1712.03893

自己紹介

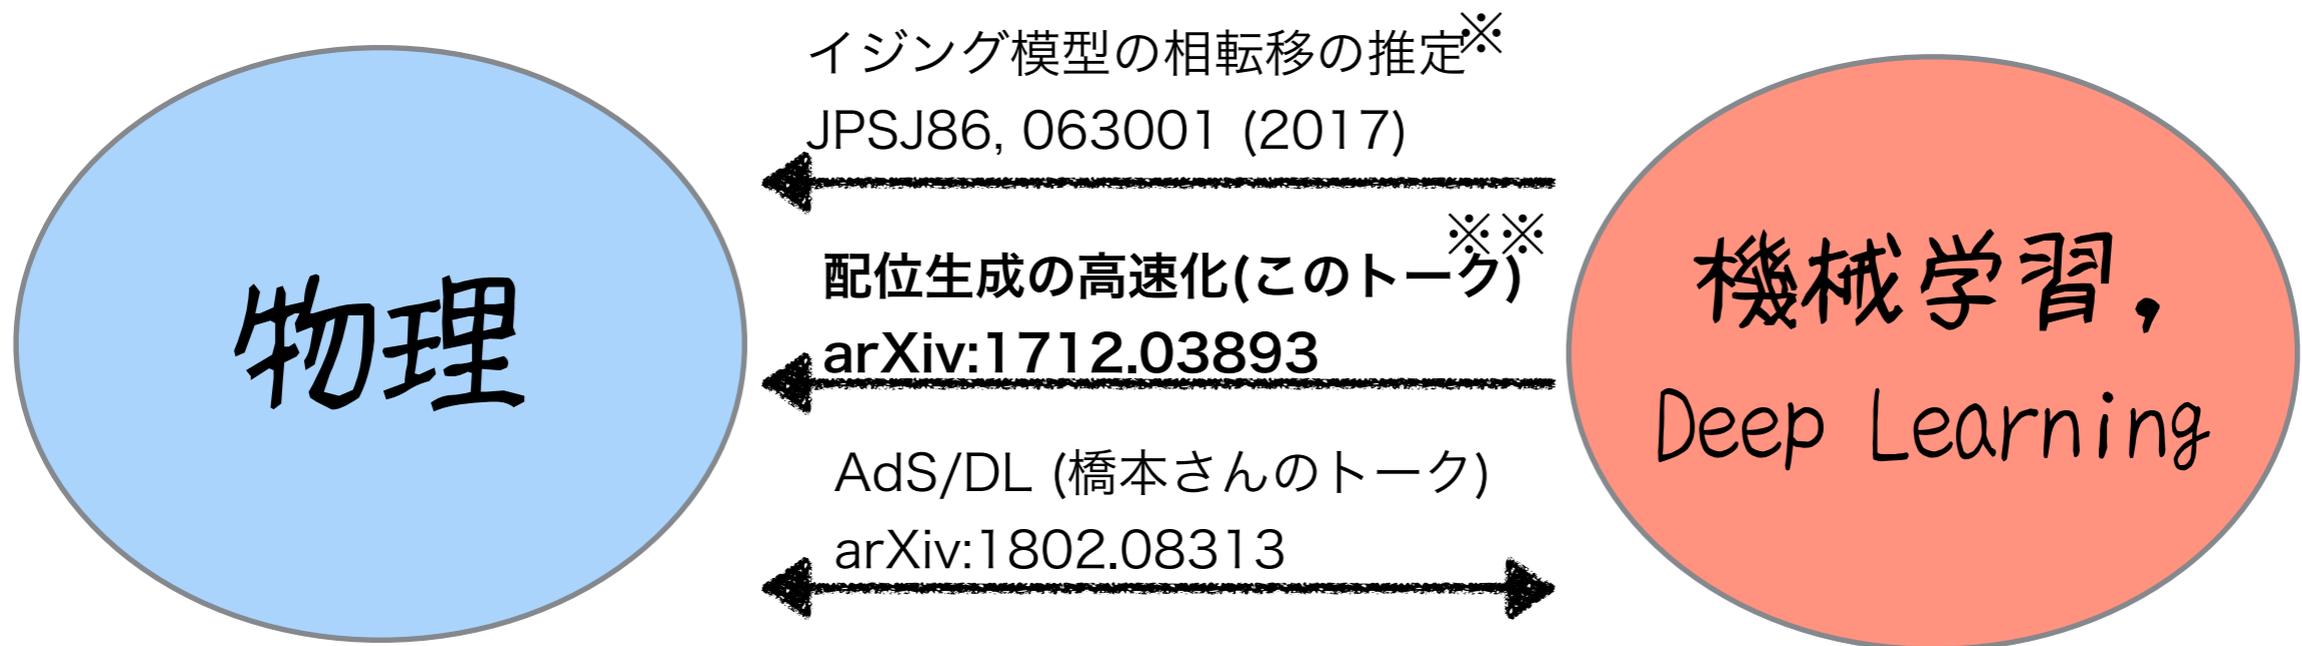
前回は機械学習を用いた測定、今回は機械学習を用いた配位生成

CCNU(中国の真ん中らへん、武漢) のポスドク

2015年 大阪大学 素粒子論研究室でPhD(田中くんと同期)。

専門: 格子QCD(数値計算で原子核などの性質を調べる)

相転移が好きで超伝導→テクニカラー→有限温度QCD、エンタングルメントエントロピー等…



関連するトーク

※柴さん、青木さん、大槻さんのトーク

※※永井さんのトーク

まとめ：問題設定と結果

提案したアルゴリズムで自己相関は短縮。相転移点で不具合

問題: 格子QCDでの配位生成を効率化したい！

効率化できれば、モンテカルロ法(HMC)からくる統計誤差を短時間で減らすことが出来る。

手法: 機械学習をHMCに組み込む

機械学習は、それっぽい画像を作れる

→ 応用できないか？

性質が良く分かってる3次元 ϕ 4理論で試してみた



Radford et al. (2015)

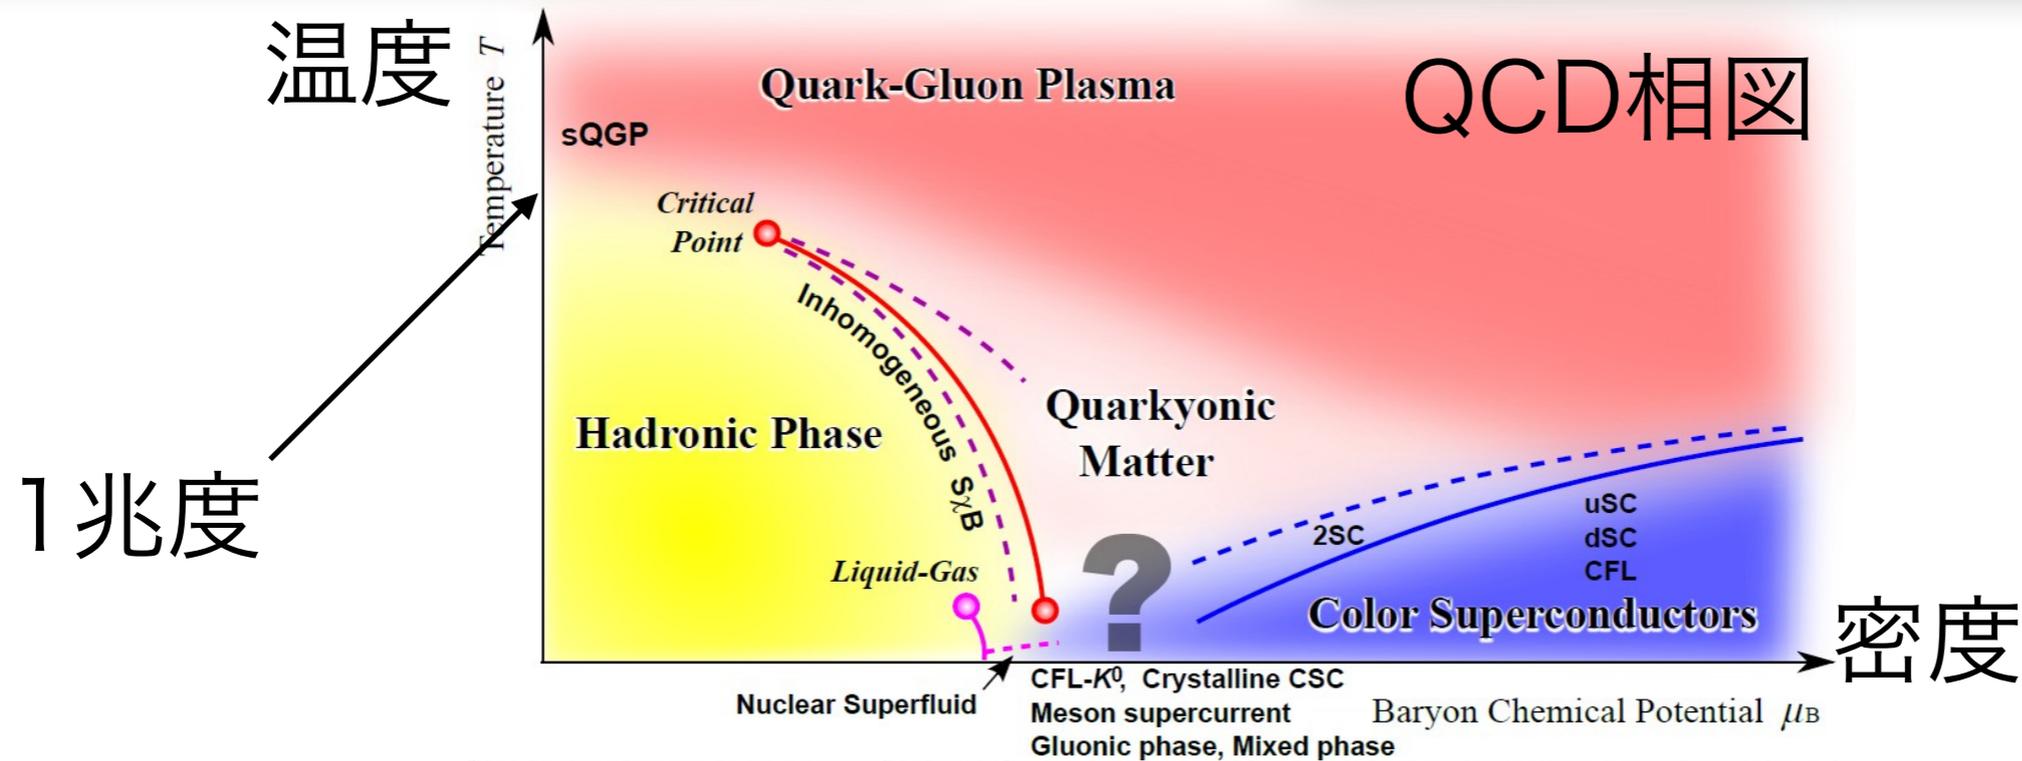
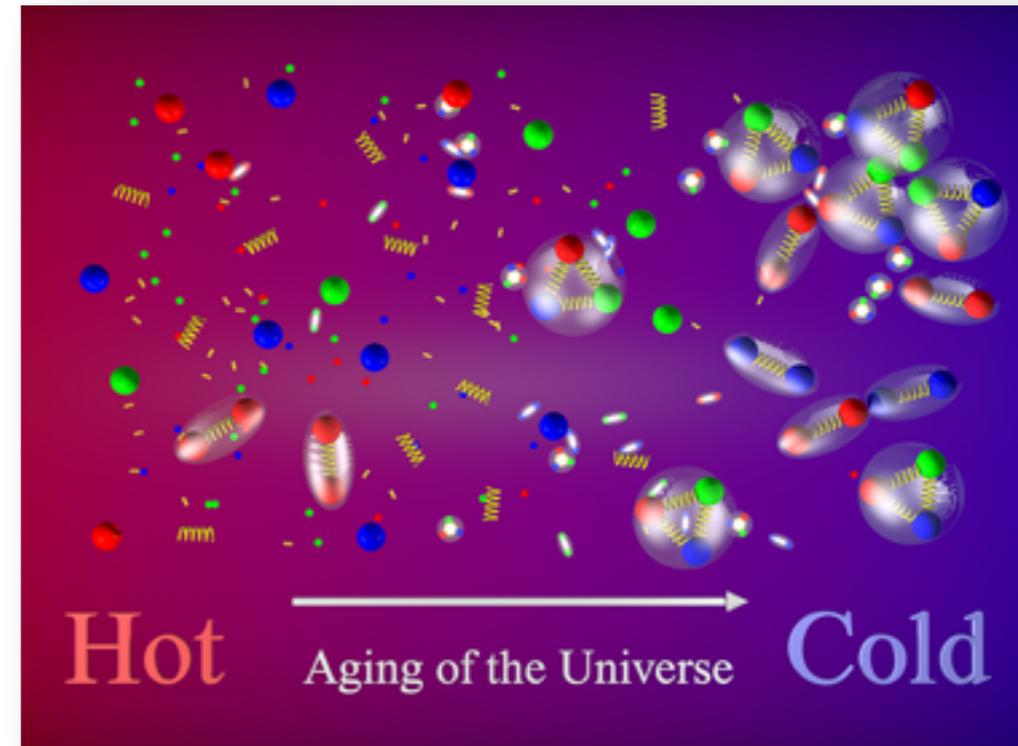
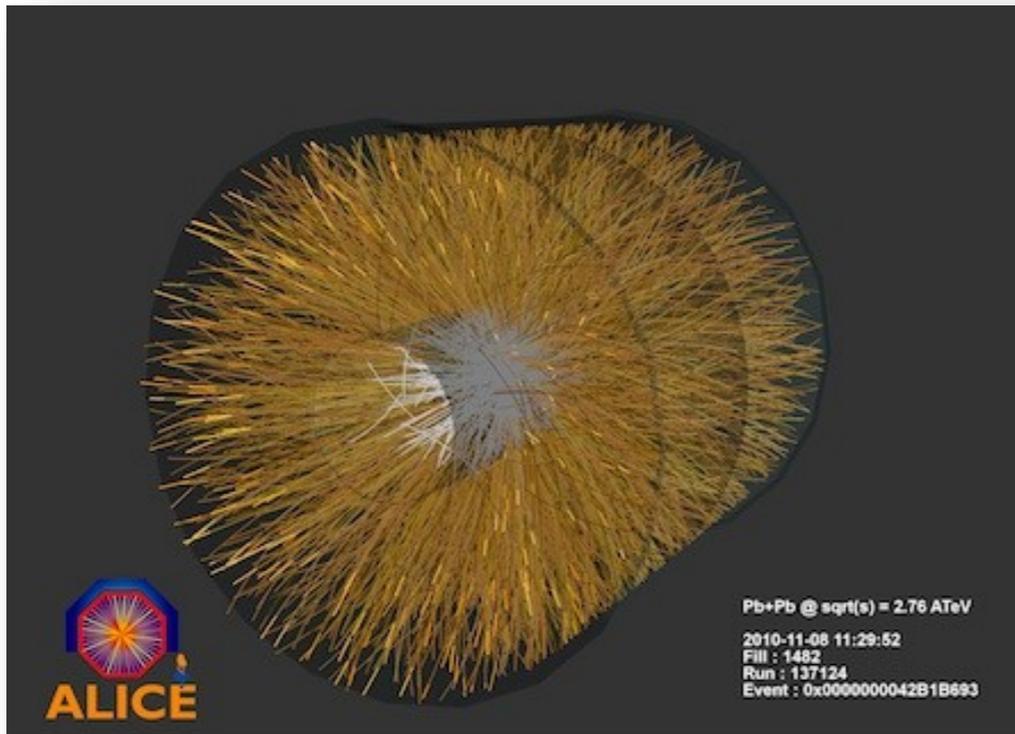
結果: 対称相、破れ相で、1点関数, 2点関数は無矛盾

臨界点で、不具合がある

背景・動機

背景: クォークとグルーオンの統計系の相構造を調べたい

原子核等は、一兆度でとけてクォークとグルーオンへ(～相転移)



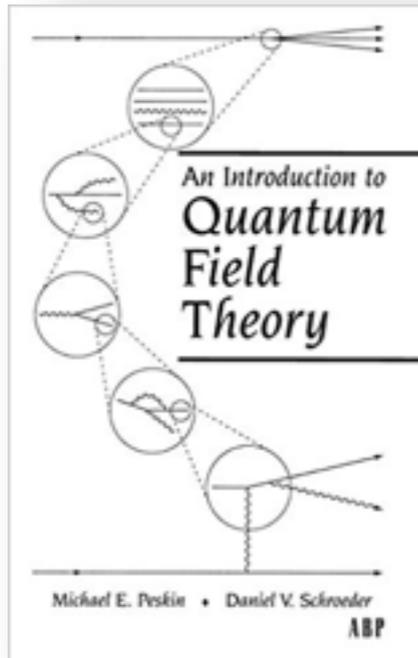
QCD相図

Fukushima-Hatsuda (2010)

※福嶋さんトーク

背景: クォークとグルーオンの統計系の相構造を調べたい

クォークとグルーオンの量子系は、摂動できない& 非摂動効果が重要



| | |
|--------------|--------|
| $q(x)$ | クォーク場 |
| $\bar{q}(x)$ | 反クォーク場 |
| $A_\mu(x)$ | グルーオン場 |

量子色力学(クォークとグルーオンの力学)の経路積分量子化

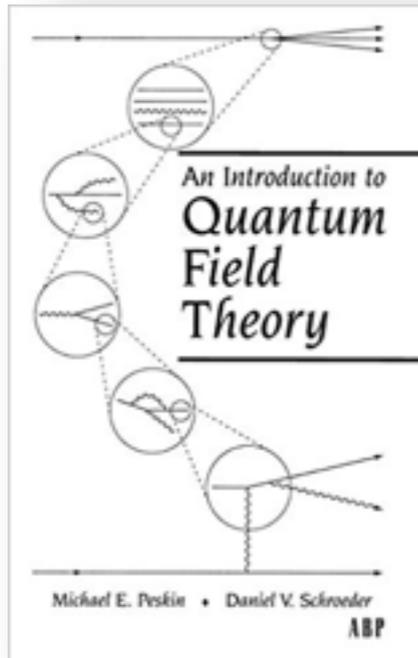
$$Z = \int \prod_x d\bar{q}(x) dq(x) dA(x) \exp \left[-\frac{1}{\hbar} \int_0^{1/(kT)} d\tau \int d^3x (\mathcal{L}_{\text{gluons}}(A) + \mathcal{L}_{\text{quarks}}(q, \bar{q}) + \mathcal{L}_{\text{interactions}}(A, q, \bar{q})) \right]$$

- 結合定数が大きいのので基本的に摂動できない
- 非摂動効果が重要であることが知られている

↑ を見てみると、統計力学の分配関数と似てる…

背景: クォークとグルーオンの統計系の相構造を調べたい

離散時空中のクォークとグルーオンの統計力学は、モンテカルロできる



$q(x)$ クォーク場
 $\bar{q}(x)$ 反クォーク場
 $A_\mu(x)$ グルーオン場

量子色力学の経路積分量子化(クォークとグルーオンの量子統計力学)

$$Z = \int \prod_x d\bar{q}(x) dq(x) dA(x) \exp \left[-\frac{1}{\hbar} \int_0^{1/(kT)} d\tau \int d^3x (\mathcal{L}_{\text{gluons}}(A) + \mathcal{L}_{\text{quarks}}(q, \bar{q}) + \mathcal{L}_{\text{interactions}}(A, q, \bar{q})) \right]$$

形式的に古典統計力学と似てるがxは、連続なので微妙に違う

→ xを離散化すれば 原子ラベルと同じ → 基本的に統計力学の手法が使える

→ 離散化した時空中の量子色力学(格子QCD)は、モンテカルロで計算できる

K. Wilson(1974)
M. Creutz(1980)

※柏さんのトーク

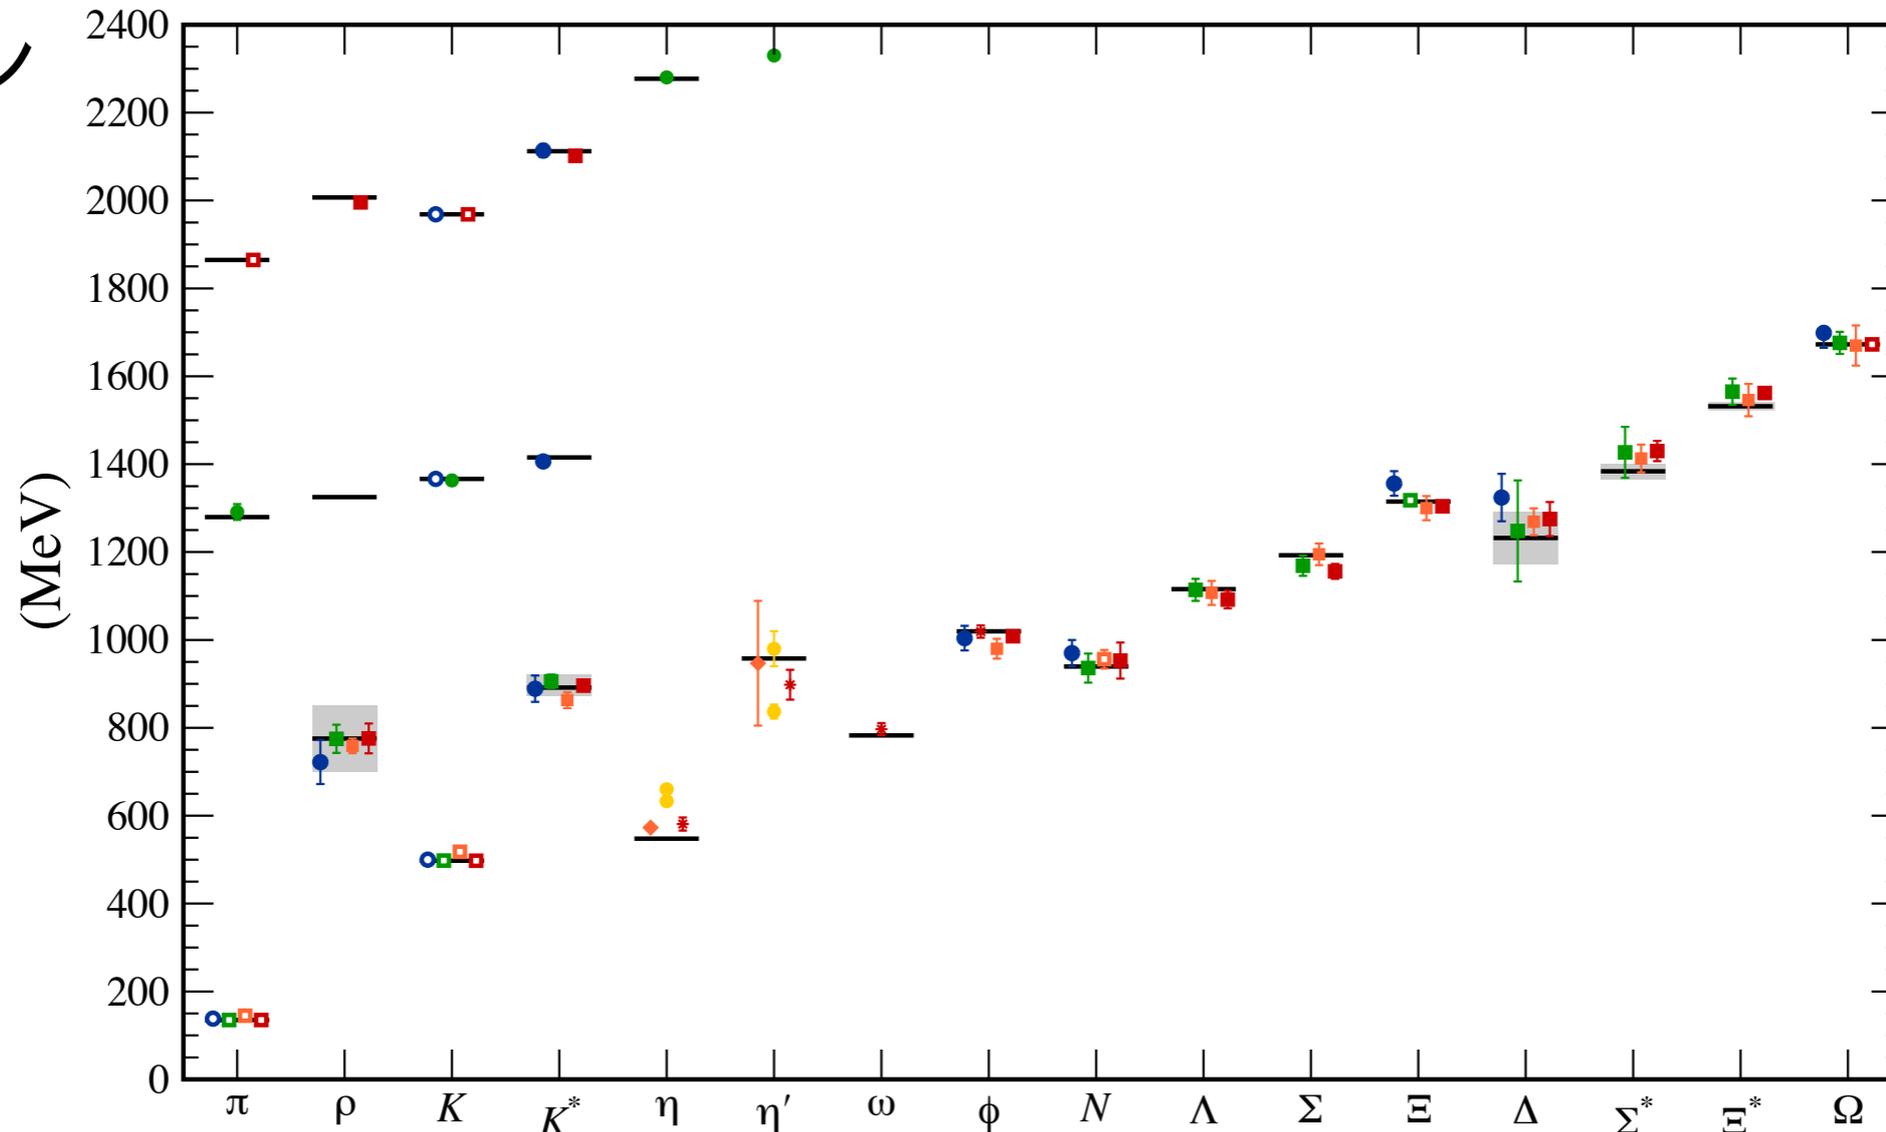
格子QCD=離散時空上のクォーク・グルーオンの量子多体系

今まで成功してきた。

線が実験で決定したハドロンの質量
シンボルが格子QCDで決定したハドロンの質量

格子QCDへ3, 4つのインプット→あう。

ハドロンの
質量



ハドロンの
種類

arXiv:1203.1204

ハイブリッドモンテカルロ法(HMC)

グルーオン場配位を連鎖的に作り出し、経路積分の結果を推定

経路積分(状態和) = すべての可能な状態の重み付け和(積分)

重み = ボルツマンweight $\sim \exp(-\int L) = \exp(-S)$

→作用S の値が大きいつき、結果への寄与は小さい

作用が小さい所の周りを重点的に計算
= ハイブリッドモンテカルロ法(HMC)

HMCの気持ち:

量子系 \sim $\frac{\text{運動方程式}}{S\text{が小さい所}}$ + $\frac{\text{ランダム運動量}}{\text{量子性}}$

HMC(ハイブリッド(ハミルトン)モンテカルロ)とは

ランダム運動量を入れた運動方程式で場を更新し、経路積分をミミックする

HMC(スカラー場版):

0. 場の配位 $\phi^{\text{old}} = \phi(x)$ を一つ選ぶ
1. ランダム運動量(場) $p(x)$ を確率 $\sim \exp(-p^2/2)$ で生成
2. $H = p^2/2 + S[\phi]$ に対するハミルトン方程式を使い
場 ϕ と運動量 p を発展 = 数值的に運動方程式を解く
(MD)
3. メトロポリス法で数値誤差を消去、 ϕ^{new} を得る

1～3を繰り返す

Simon Duane, A.D. Kennedy, Brian J. Pendleton, and
Duncan Roweth. Hybrid monte carlo. Physics Letters B,
195(2):216 – 222, 1987.

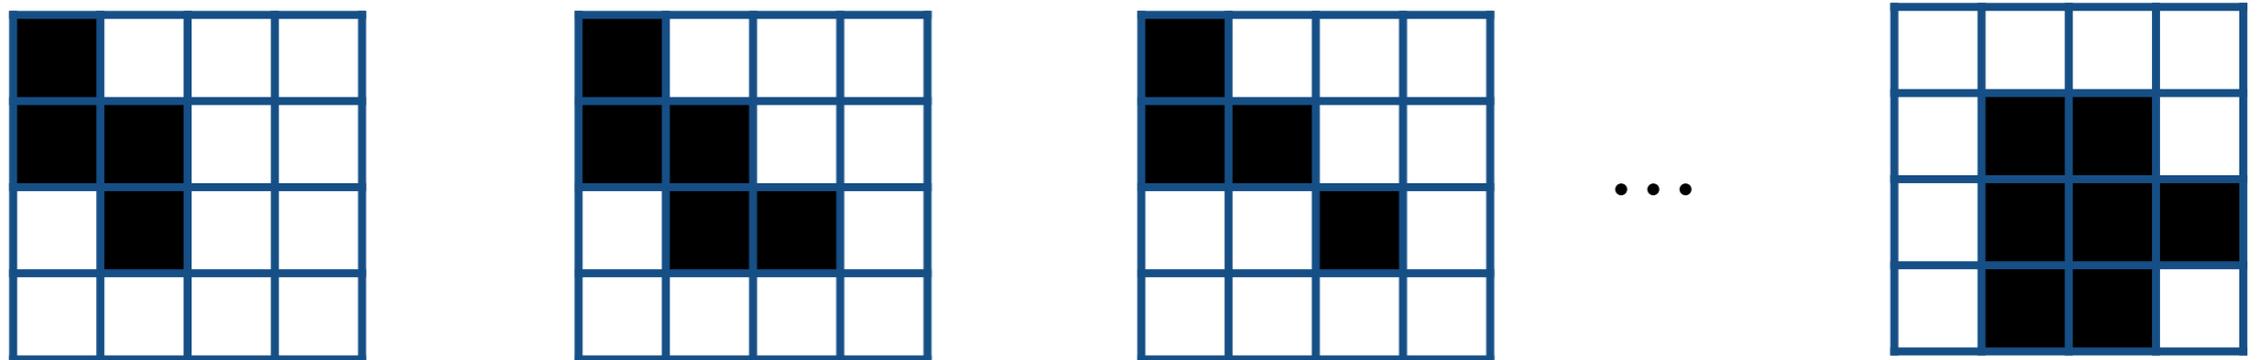
場の配位の列 ϕ_1, ϕ_2, \dots の平均 = 期待値

無限回やれば厳密に経路積分に一致することが知られている

自己相関時間

ランダム運動量を入れた運動方程式で場を更新し、経路積分をミミックする

HMC(ハイブリッドモンテカルロ)を使うと、場の配位の列 ϕ_1, ϕ_2, \dots が得られる。



場のラベル ϕ_1 ϕ_2 ϕ_3 ... ϕ_N

黒の数 4 5 4 ... 7



黒のセルの数が近いので、独立な配位とみなせない
 → 似ている範囲を自己相関時間と呼ぶ(短い方が良い)

自己相関を短くして、高効率なサンプリングを

似たような場の配位のサンプル → 有効的な統計数の減少

HMCの気持ち:

$$\text{量子系} \sim \frac{\text{運動方程式}}{S \text{が小さい所}} + \frac{\text{ランダム運動量}}{\text{量子性}}$$

- (仮想)時間での発展が有効的に遅くなるときを考える
- = 同じ計算時間でも似た場の配位のみが出てくる
- ランダムサンプリングとして効率の低下

なんとかしたい！

目次

✓1. 動機と導入

2. ボルツマンマシン

3. 先行研究

4. やったこと

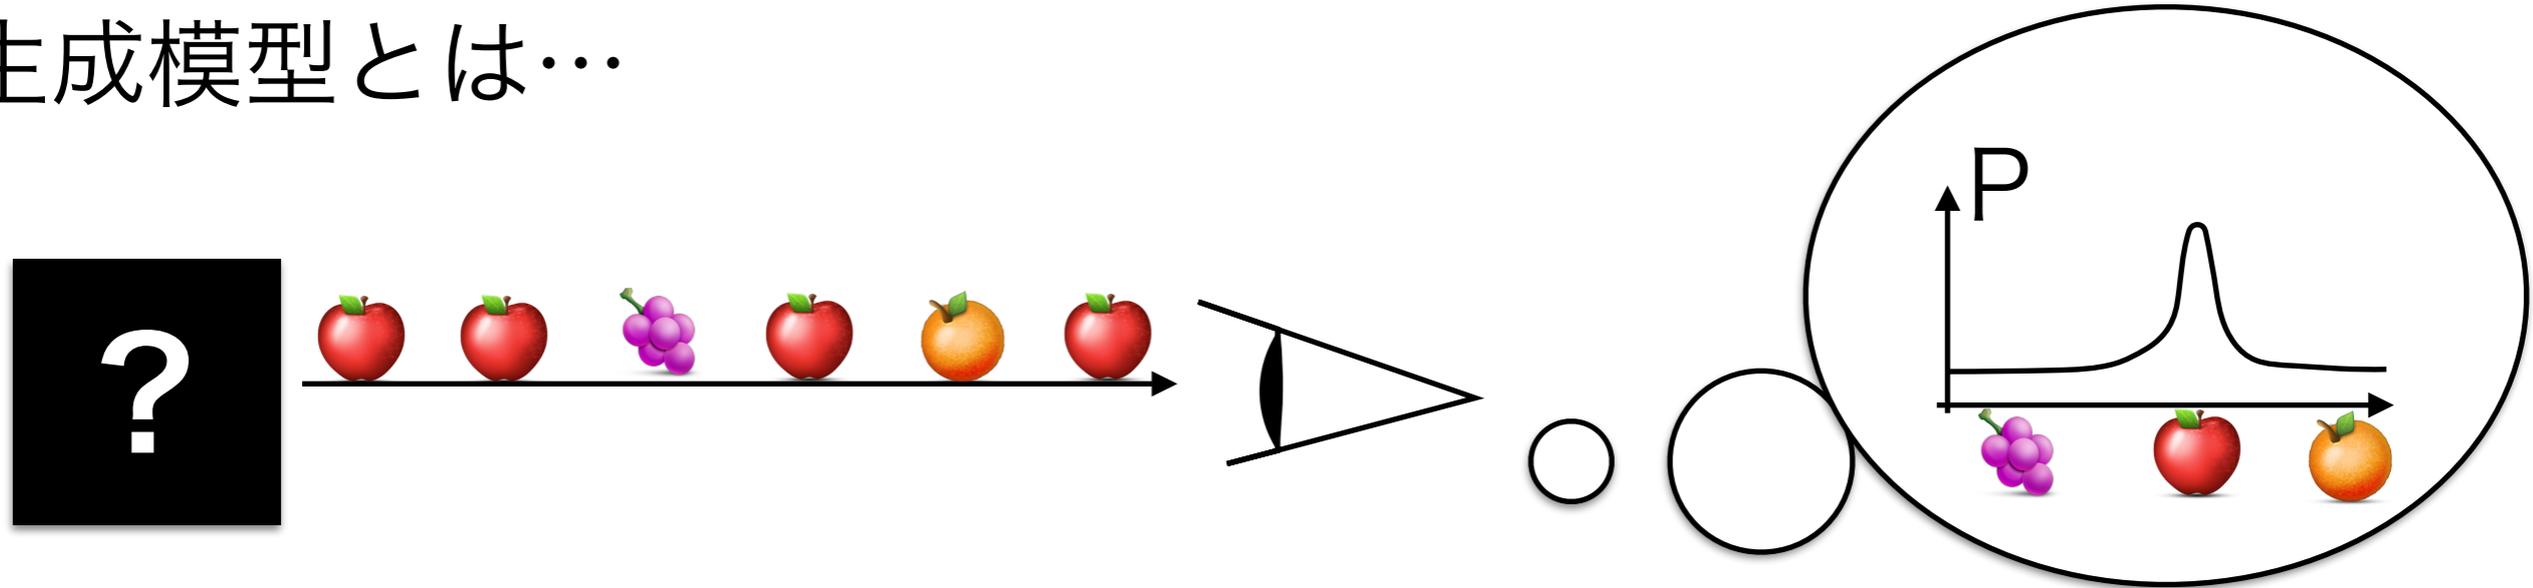
5. 結果

ボルツマンマシン

生成模型、ボルツマンマシン

生成モデルは、経験確率に基づき、模倣したデータを生成できる

生成模型とは…



ブラックボックス(情報源)から情報が出て来るとして、
情報源をモデル化、模倣する機械学習の枠組みの1つ。
 情報は、適当な確率分布に従って生成されてると考える

ボルツマンマシンは、生成模型の1つ
情報源から出てくる確率と模型の確率を似せる(最尤法)

制限ボルツマンマシン

生成モデルの一種で、経験に基づき、模倣データを生成できる

ボルツマンマシン ≡ イジング模型、2種のスピン自由度 v, h (両方2値) :

※大関さん、柴さんのトーク

制限ボルツマンマシン: v 同士、 h 同士には結合のない生成模型

$$E[v, h] = \sum_n b_n v_n + \sum_i c_i h_i + \sum_{nj} v_n w_{nj} h_j$$

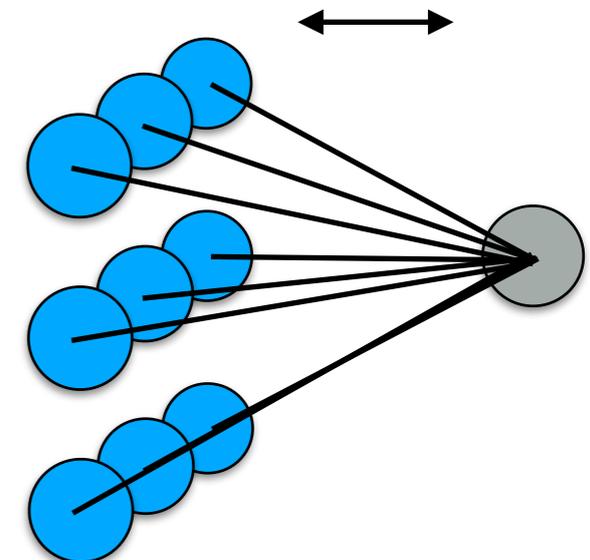
$$\mathcal{P}(v, h) = \frac{1}{Z} e^{-E[v, h]}$$

学習パラメータ: b, c, w

v, h は、スピン自由度(に対応)

v に値を入力 → h に関する確率分布

h に値を入力 → v に関する確率分布



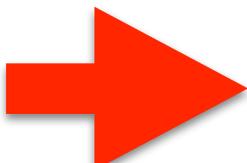
通常 v (可視層)には、画像データを入力し、画像の分布を模倣する
学習パラメータは、勾配法で P を最大化するように学ばれる

ガウシアン制限ボルツマンマシンGRBM

vのspin自由度を連続変数にしたもの. hは2値

ガウシアン制限ボルツマンマシン = 可視層の変数を連続なモノにしたversion

$$E[v, h] = \sum_n b_n v_n + \sum_i c_i h_i + \sum_{nj} v_n w_{nj} h_j$$



$$H_{\theta}^{\text{GRBM}}[\phi, h] = \sum_n \frac{(\phi_n - a_n)^2}{2\sigma_n^2} - \sum_j b_j h_j - \sum_{n,j} \frac{\phi_n}{\sigma_n} w_{nj} h_j,$$

a, σ , b, w が学習パラメータ

通常 v(可視層)には、画像データを入力し、画像の分布を模倣する学習パラメータは、勾配法でPを最大化するように学ばれる

先行研究

Self-Learning Monte-Carlo(SLMC)

有効模型の係数を実際のシミュレーション結果から決める

永井さんのトーク：

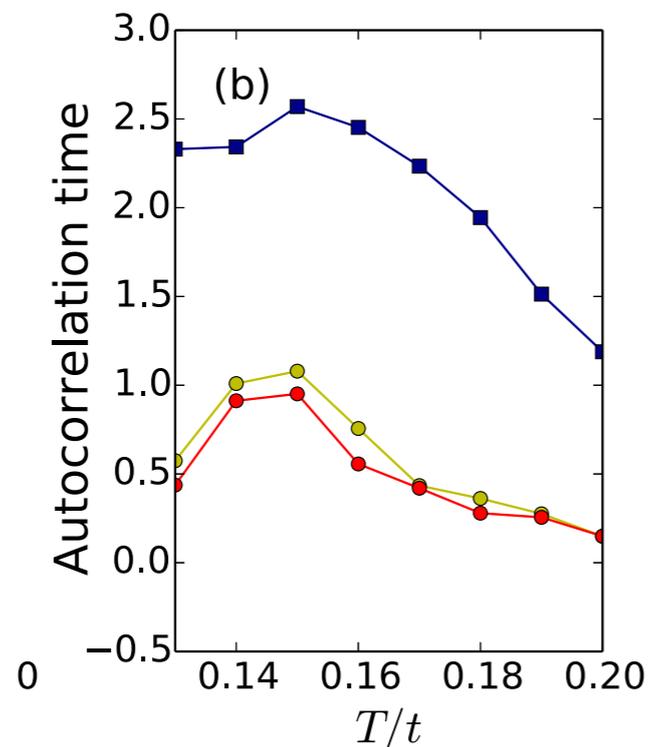
アイデア: 自己相関が長い系の厳密なハミルトニアンが分かっていると
係数をパラメータにした有効ハミルトニアンを用意し、シミュレーションと
回帰で係数を決める。有効系でシミュレーションし、自己相関を切る。
メトロポリステストで、厳密なハミルトニアンに対する分布に補正する。

上手いこといってる

RBMを用いたイジングの配位生成

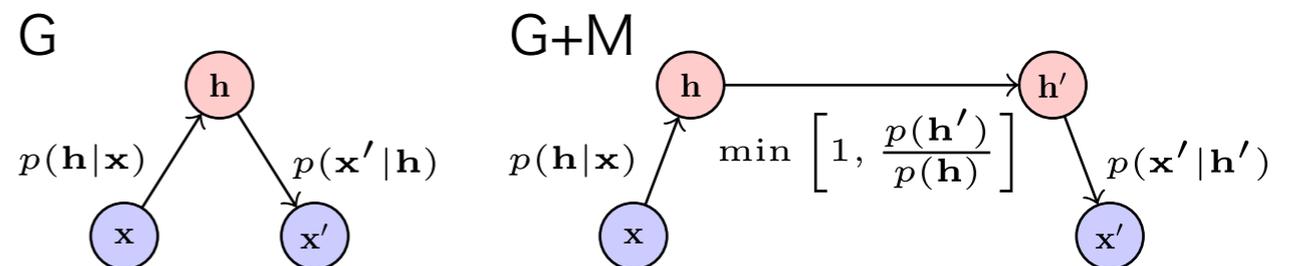
RBMのみでイジングの配位を生成する

中国科学院組



The Falicov-Kimball model

$$\hat{H}_{\text{FK}} = \sum_{i,j} \hat{c}_i^\dagger \mathcal{K}_{ij} \hat{c}_j + U \sum_{i=1}^N \left(\hat{n}_i - \frac{1}{2} \right) \left(x_i - \frac{1}{2} \right),$$



有効ハミルトニアンを使わずに、配位を生成

上手いこといってるらしい。

やったこと

機械学習で場の理論の配位を生成した

初の試みなので、多面的にチェックが必要

ボルツマンマシン+HMCで配位生成をし、
自己相関の短縮を試みた。

場の理論の配位生成への初の応用なので
何が起こるかわからない…

格子上の3次元 ϕ^4 でやってみた。
→ よく理解されている模型なので
問題があればすぐにわかる。

HMC(ハイブリッドモンテカルロ)とは

ランダム運動量を入れた運動方程式で場を更新し、経路積分をミミックする

HMC(スカラー場版):

再掲

0. 場の配位 $\phi^{\text{old}} = \phi(x)$ を一つ選ぶ
1. ランダム運動量(場) $p(x)$ を確率 $\sim \exp(-p^2/2)$ で生成
2. $H = p^2/2 + S[\phi]$ に対するハミルトン方程式を使い
場 ϕ と運動量 p を発展 = 数値的に運動方程式を解く
3. メトロポリス法で数値誤差を消去、 ϕ^{new} を得る

1~3 を繰り返す

場の配位の列 ϕ_1, ϕ_2, \dots が得られるので、期待値を求める

提案したアルゴリズム

配位の更新を運動方程式のみでなく、経験分布もつかう

Boltzmann machine + HMC(スカラー場版):

0. 場の配位 $\phi^{\text{old}} = \phi(x)$ を一つ選ぶ

1. ランダム運動量(場) $p(x)$ を確率 $\sim \exp(-p^2/2)$ で生成

Added

1.5. 学習済のボルツマンマシンに配位 ϕ をいれ、新配位 ϕ を生成

2. $H = p^2/2 + S[\phi]$ に対するハミルトン方程式を使い

場 ϕ と運動量 p を発展 = 数値的に運動方程式を解く

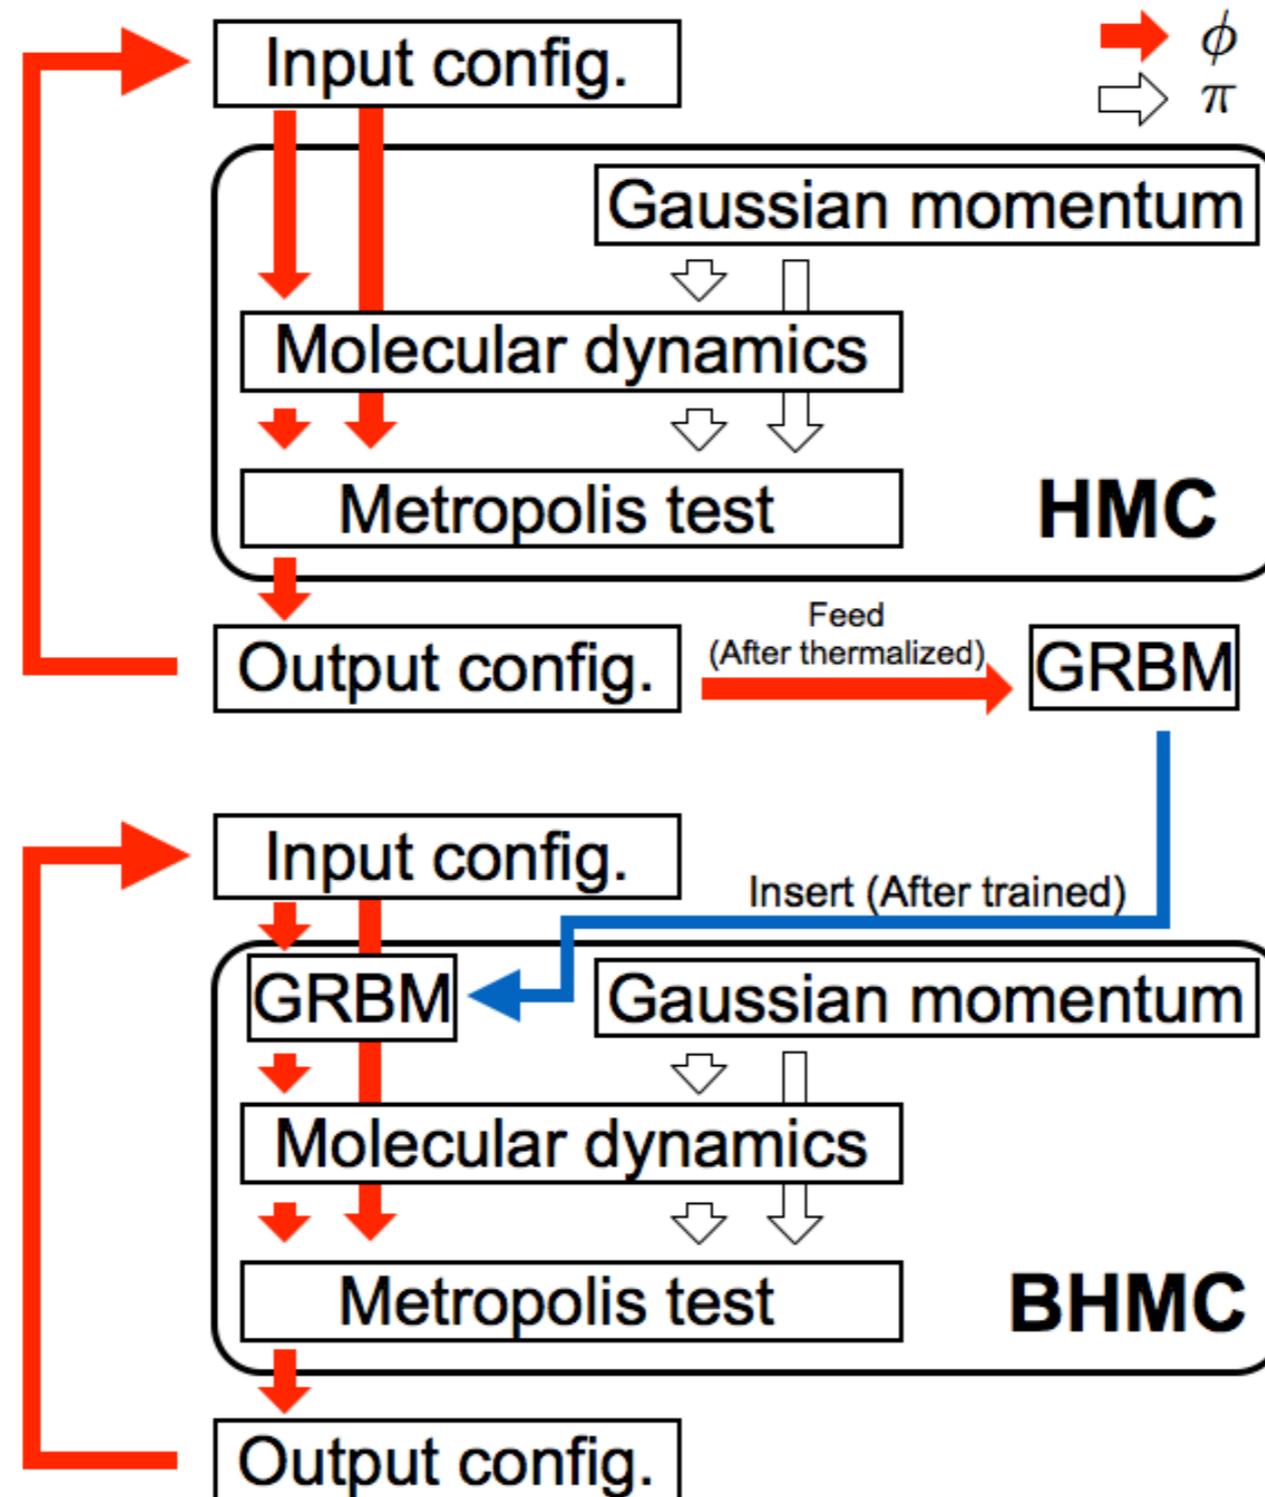
3. メトロポリス法で数値誤差を消去、 ϕ^{new} を得る

1~3 を繰り返す

場の配位の列 ϕ_1, ϕ_2, \dots が得られるので、期待値を求める

実際の運用のながれ

最初は、HMCのみで配位を生成。学習が進めば、ボルツマンマシンを挿入。



ϕ^4 理論

3次元格子上的 ϕ^4 理論の計算を行った

$$S[\phi] = \sum_n^N \left[-\frac{1}{2} \phi_n \Delta \phi_n + \frac{m^2}{2} \phi_n^2 + \frac{\lambda}{4!} \phi_n^4 \right].$$

$$\langle O \rangle = \frac{1}{\mathcal{Z}_{\text{lat}}} \int \mathcal{D}\phi O[\phi] e^{-S[\phi]},$$

古典的には、

$m^2 < 0$: Z_2 対称性が自発的にやぶれた相に。そうでなければ、対称相

対称相、破れ相そして臨界点で計算をおこなった

測定した物理量

作用密度、1点関数、2点関数

代表的な物理量である作用密度、1点関数、2点関数をしらべた。作用密度と1点関数はヒストグラムも計算。1点関数の自己相関を2つのアルゴリズムで比較した

$$\bar{S}/V = \frac{1}{V} \frac{1}{N_{\text{conf}}} \sum_{c=1}^{N_{\text{conf}}} S[\phi^{(c)}],$$

$$\bar{\phi}/V = \frac{1}{N_{\text{conf}}} \sum_{c=1}^{N_{\text{conf}}} \frac{1}{V} \sum_n \phi_n^{(c)},$$

$$\bar{G}(t) = \sum_{dx, dy=1}^{N_x, N_y} \frac{1}{N_{\text{conf}}} \sum_{c=1}^{N_{\text{conf}}} \frac{1}{V} \sum_n \phi_{t+n_t, dx+n_x, dy+n_y}^{(c)} \phi_n^{(c)},$$

(破れ相では、con. part)

結果

統計と結果

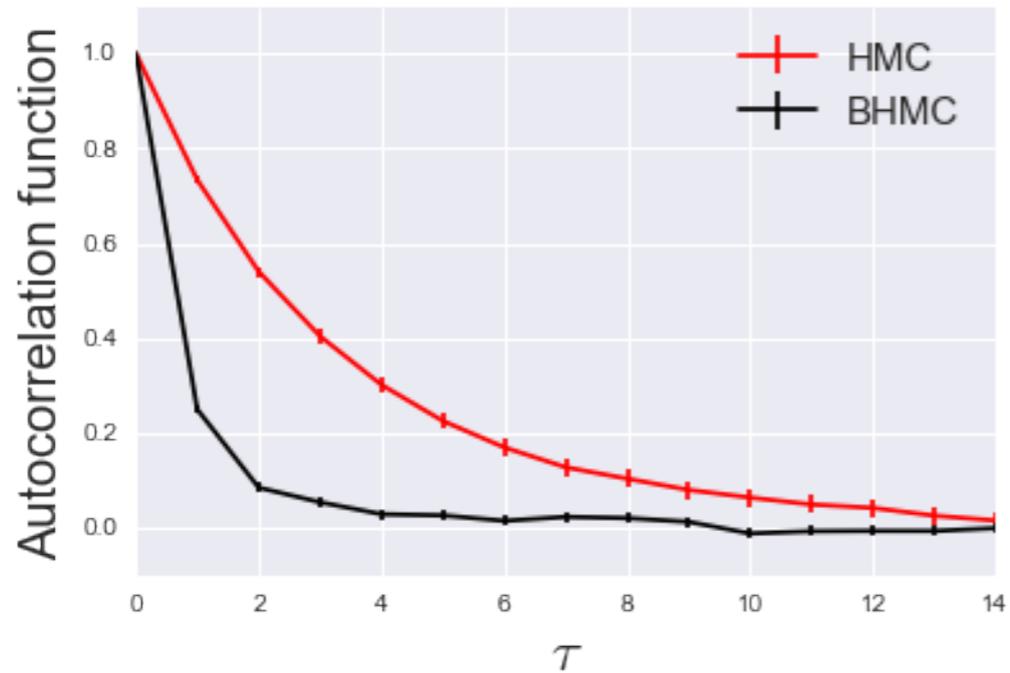
数字だけ見ると良さそうに見える

| Alg. | Phase | N_{conf} | $\langle \phi \rangle / V$ | $\langle S \rangle / V$ | τ_{int} |
|------|-----------|-------------------|----------------------------|-------------------------|---------------------|
| HMC | Symmetric | 10^4 | 0.00 ± 0.05 | 0.48 ± 0.03 | 4.4 ± 0.3 |
| | Broken | 10^4 | -3.94 ± 0.04 | -2.70 ± 0.03 | 2.8 ± 0.2 |
| BHMC | Symmetric | 10^4 | 0.00 ± 0.04 | 0.50 ± 0.04 | 2.0 ± 0.1 |
| | Broken | 10^4 | -3.95 ± 0.03 | -2.73 ± 0.04 | 2.5 ± 0.2 |

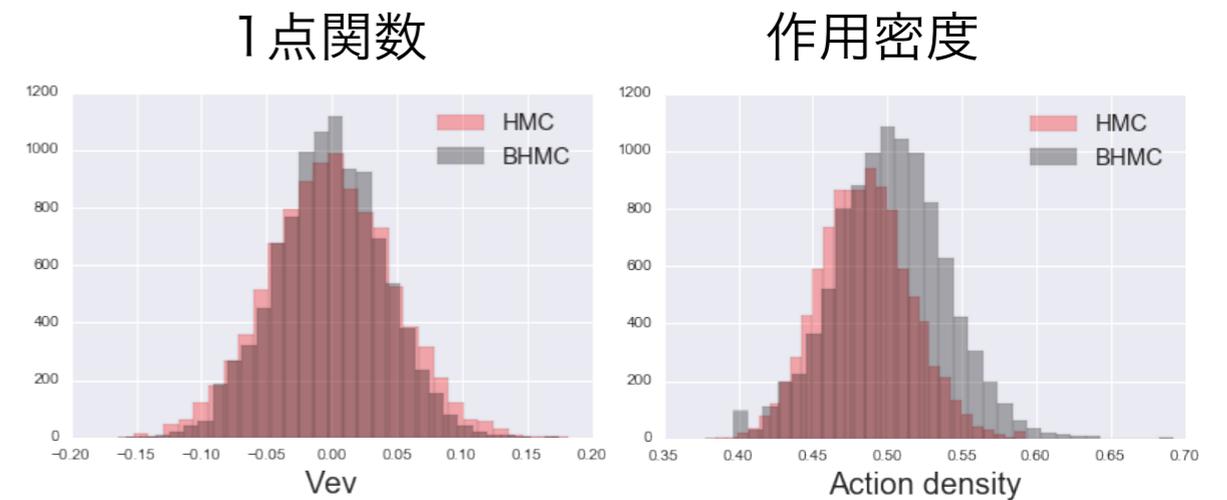
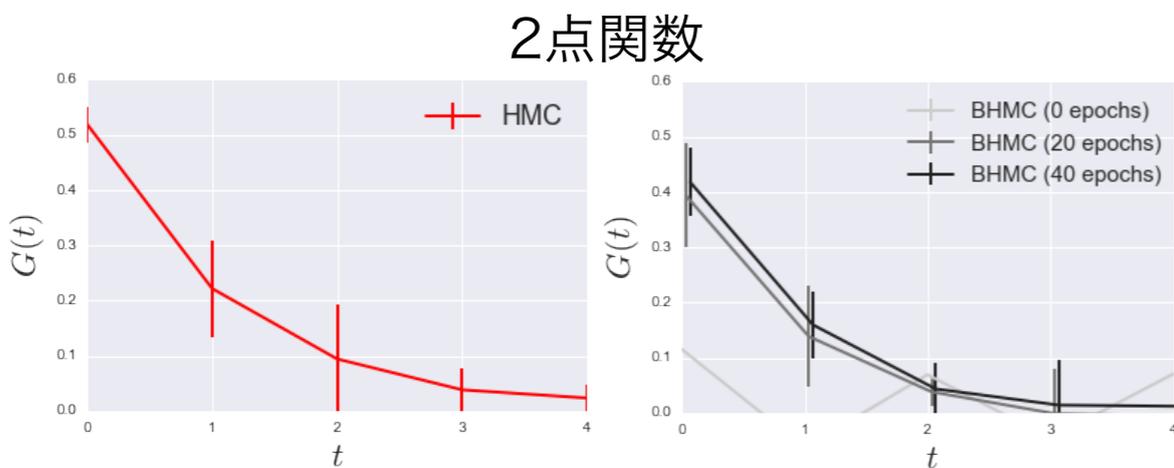
一見良さそうに見えるが…？

結果

対称相での結果

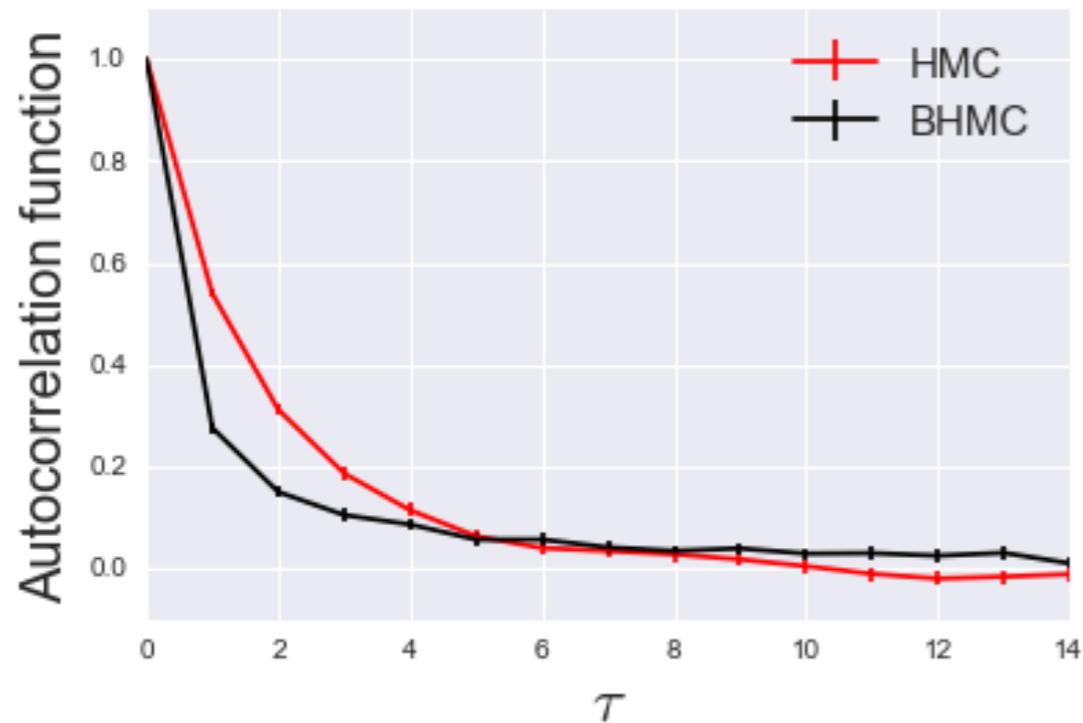


- 自己相関は、短くなる
- 1点関数、2点関数はコンシステント
- 作用密度が少しズレている



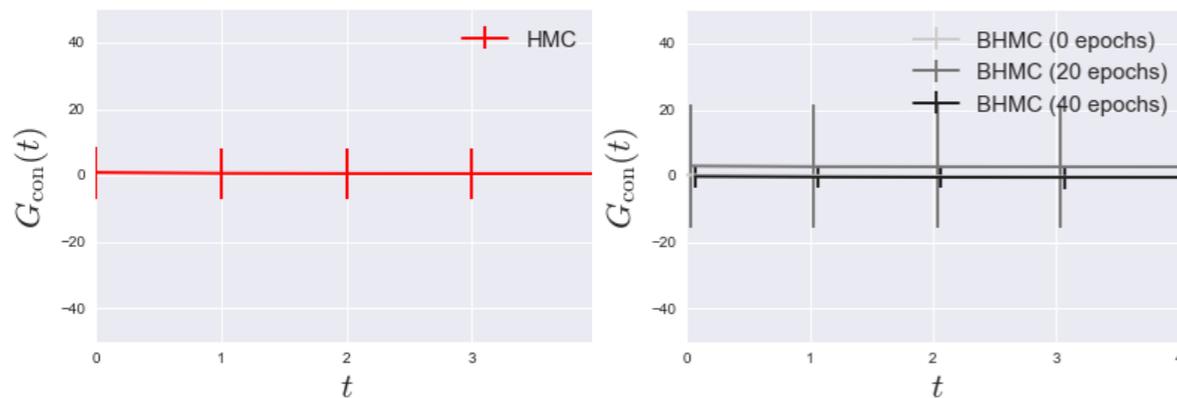
結果

破れ相での結果

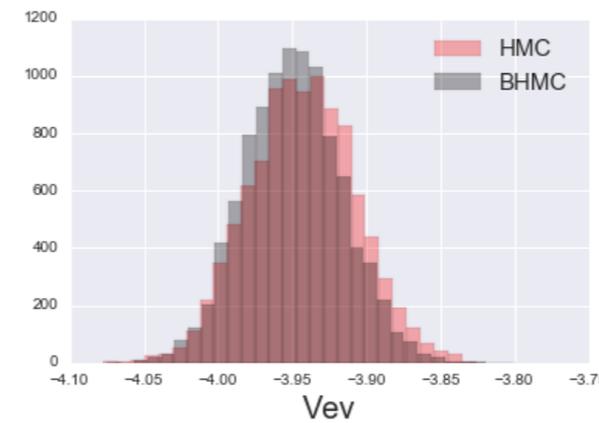


- 自己相関は、(少し)短くなる
- 1点関数、2点関数はコンシステント
- 作用密度が少しズレている

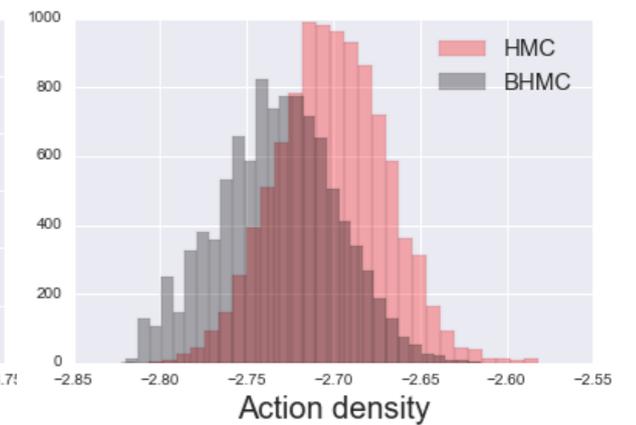
2点関数



1点関数

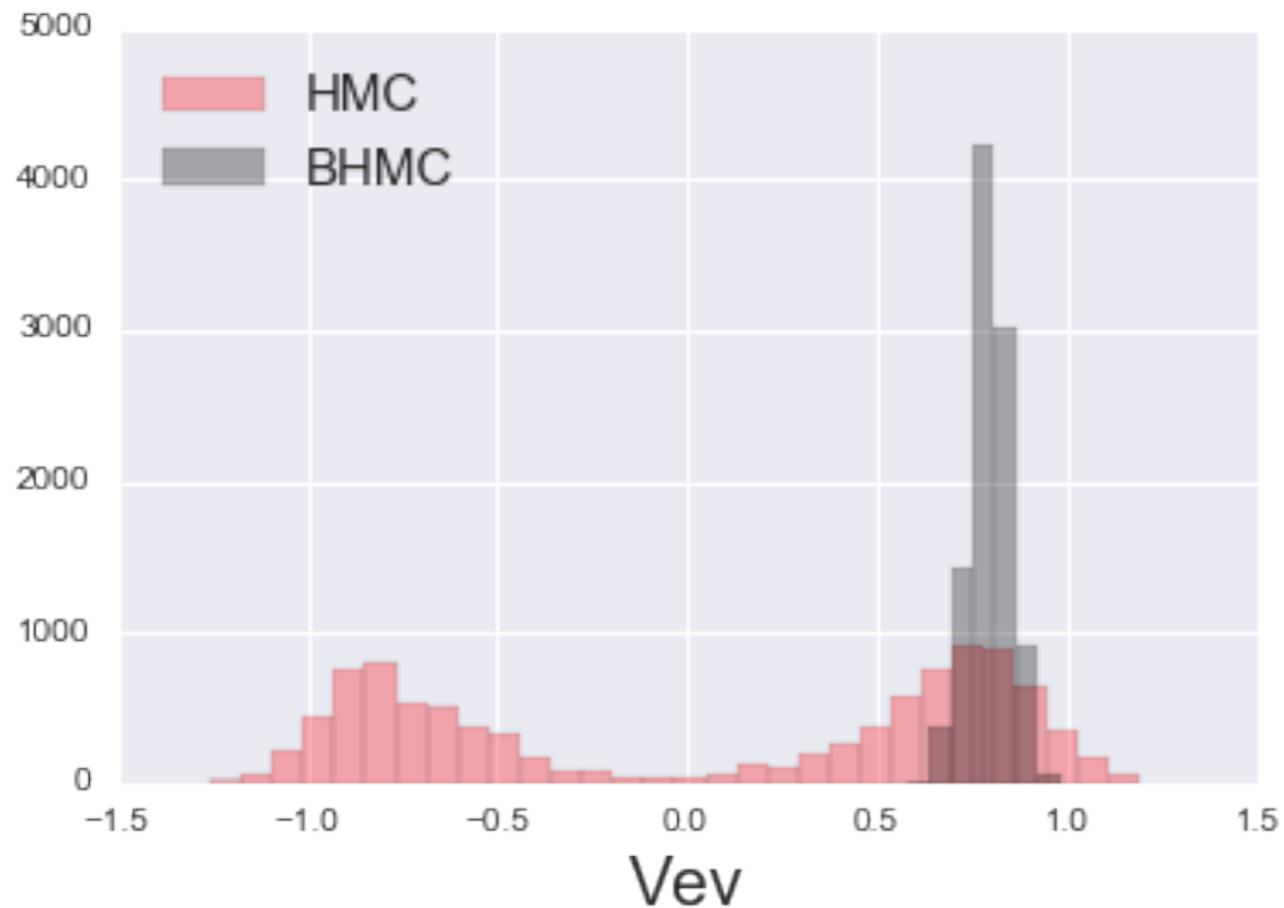


作用密度



結果

臨界点での結果



- 1点関数すら合わない

ボルツマンマシンの限界？

機械学習のモデルを変えればうまくいく？

結果を省みる

モデルの表現力？

機械学習のモデルを変えればうまくいく？

$$H_{\theta}^{\text{GRBM}}[\phi, h] = \sum_n \frac{(\phi_n - a_n)^2}{2\sigma_n^2} - \sum_j b_j h_j - \sum_{n,j} \frac{\phi_n}{\sigma_n} w_{nj} h_j,$$

$$p_{\theta}[\phi, h] = \frac{e^{-H_{\theta}^{\text{GRBM}}[\phi, h]}}{\mathcal{Z}_{\theta}},$$

ボルツマンマシンは、本質的にガウス分布。

混合ガウス分布にする？

GAN(Generative Adversarial Networks) などより表現力の高い模型？

理論的に経路積分に収束する模型？(あるのか?)

まとめ：問題設定と結果

提案したアルゴリズムで自己相関は短縮。相転移点で不具合

問題: 格子QCDでの配位生成を効率化したい！

効率化できれば、モンテカルロ法(HMC)からくる統計誤差を短時間で減らすことが出来る。

手法: 機械学習をHMCに組み込む

機械学習は、それっぽい画像を作れる

→ 応用できないか？

性質が良く分かってる3次元 ϕ 4理論で試してみた



Radford et al. (2015)

結果: 対称相、破れ相で、1点関数, 2点関数は無矛盾

臨界点で、不具合がある

バックアップ

自己相関

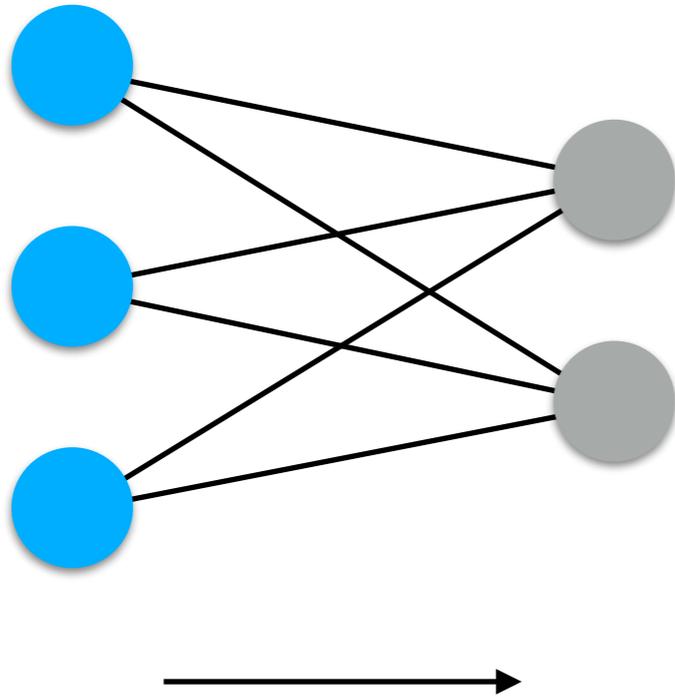
MCMCでつくられる配位間の類似性

$$\bar{\Gamma}(\tau) = \frac{1}{N_{\text{conf}} - \tau} \sum_c^{N_{\text{conf}}} (O_c - \bar{O})(O_{c+\tau} - \bar{O}),$$

ニューラルネットワークとボルツマンマシン

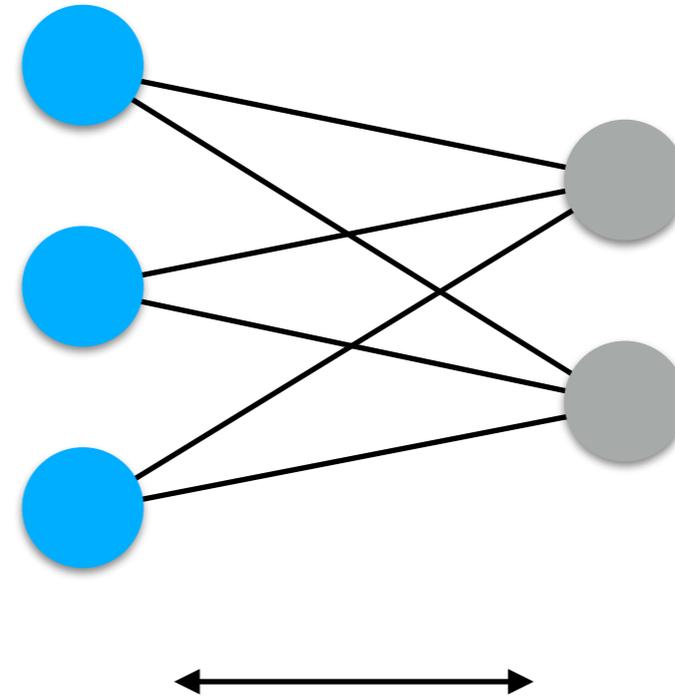
ニューラルネットワーク=一方向, ボルツマンマシン=双方向

ニューラルネット



決定論的
正解と出力を合わせる

ボルツマンマシン



確率論的
分布を近づける