

# 機械学習が抽出する特徴と イジング模型の相転移点

船井 正太郎 (株式会社アラヤ)

---

2022年10月27日 @ 「ディープラーニングと物理学 オンライン」

# 「初めてまして」の方も多いと思いますので...

名前：船井 正太郎

2017年まで 柴 正太郎

論文では Shotaro Shiba Funai

研究分野：

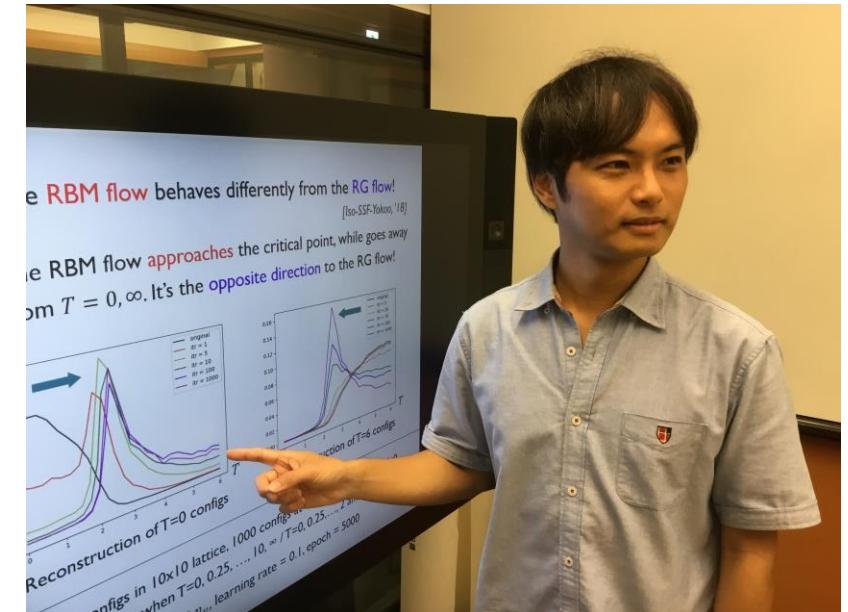
2015年まで 物理学の超弦理論の研究

2016年から 機械学習の研究

職歴：

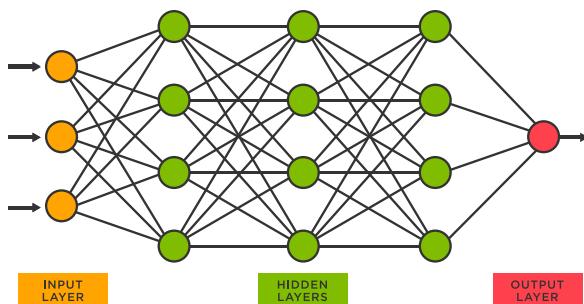
学振研究員(PD)、益川塾とKEKの博士研究員、OISTの研究員などを経て、

2022年10月から 株式会社アラヤのチーフリサーチャー

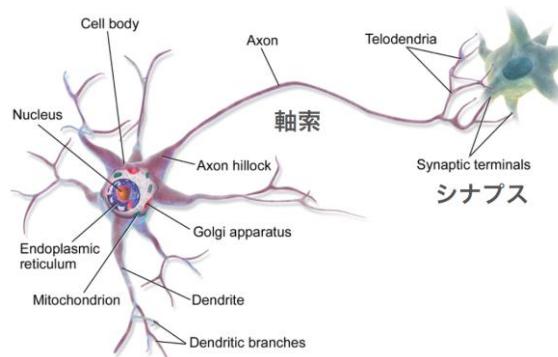


# 最も根底にある興味は...

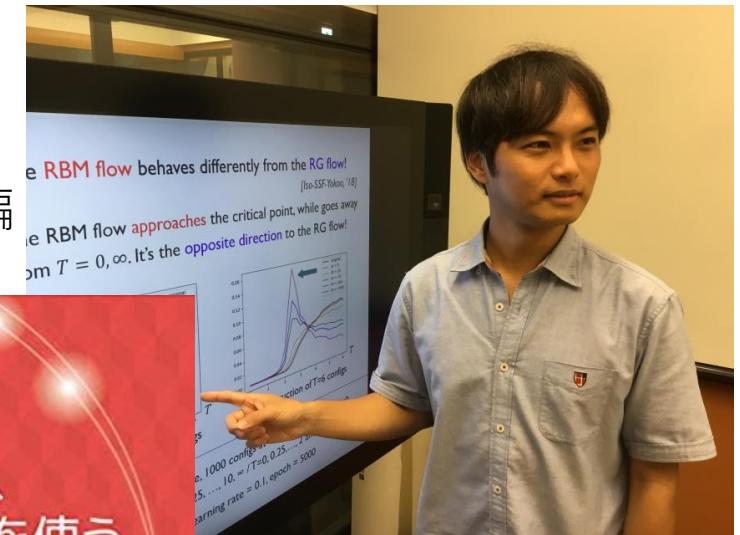
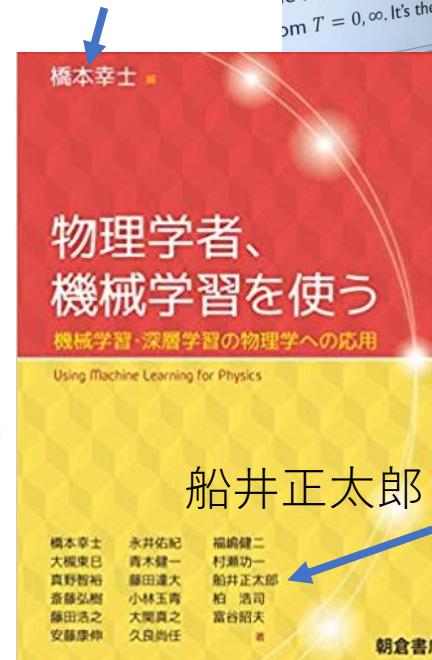
機械学習 (AI) が数値的に捉えられる、  
データの「特徴」とは結局何なのか?  
可能ならば物理学の概念を応用して  
理解したい！



<https://www.tibco.com/>



橋本幸士さん編



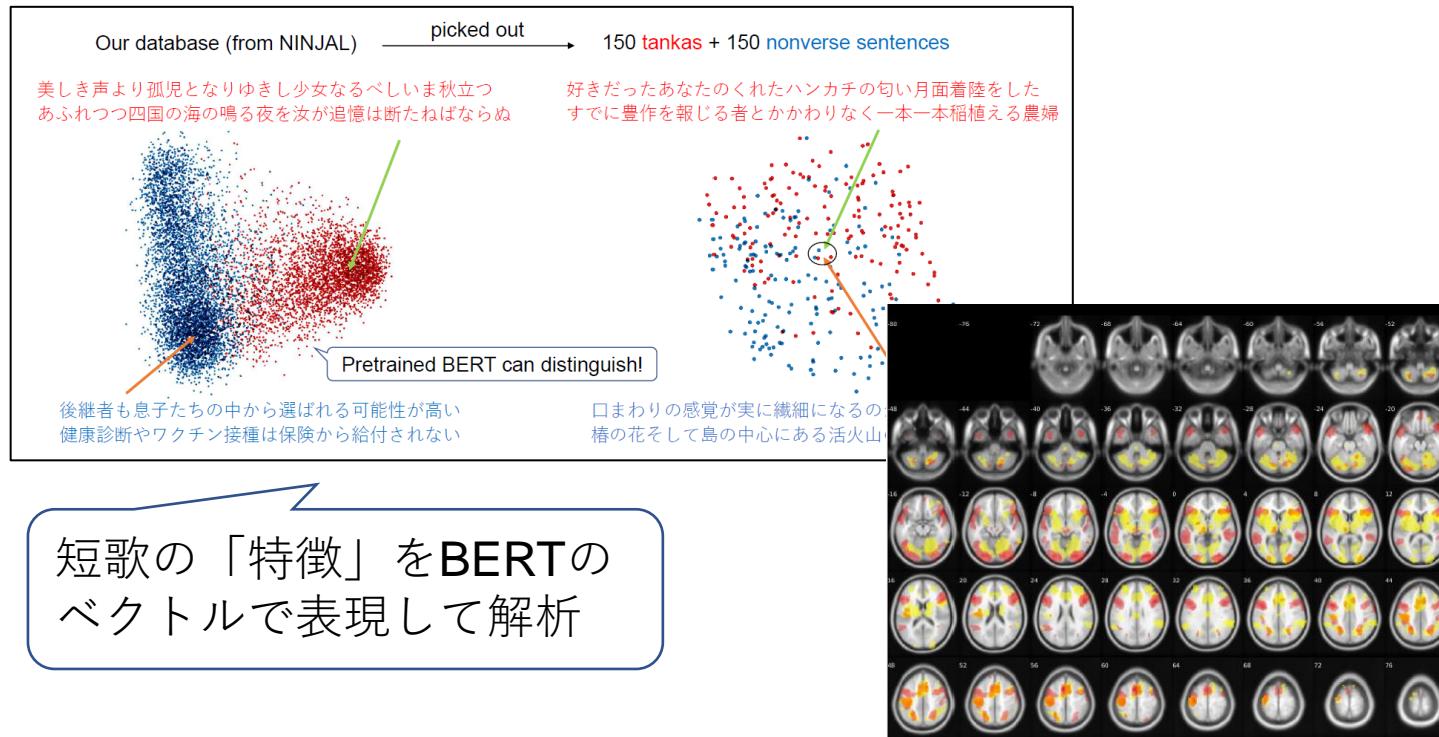
船井正太郎 (第10章)



もし機械学習が本当に脳や意識の toy model と見做せるならば、  
「意識の物理学」が創れるかもしれない...?

# 研究1：機械学習は短歌を鑑賞できるのか？

(機構間連携におけるプロジェクト、2019年から)

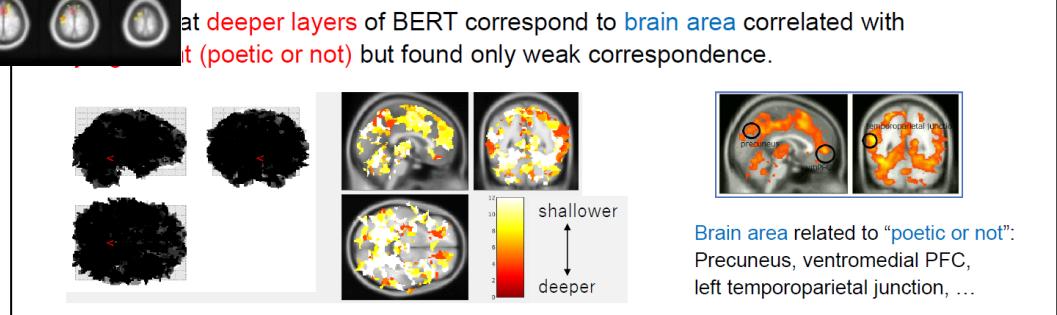


短歌の「特徴」をBERTの  
ベクトルで表現して解析

短歌を読むときの人間の脳をfMRIで  
計測して、BERTベクトルとの対応  
(各部位・各層の相関) を解析



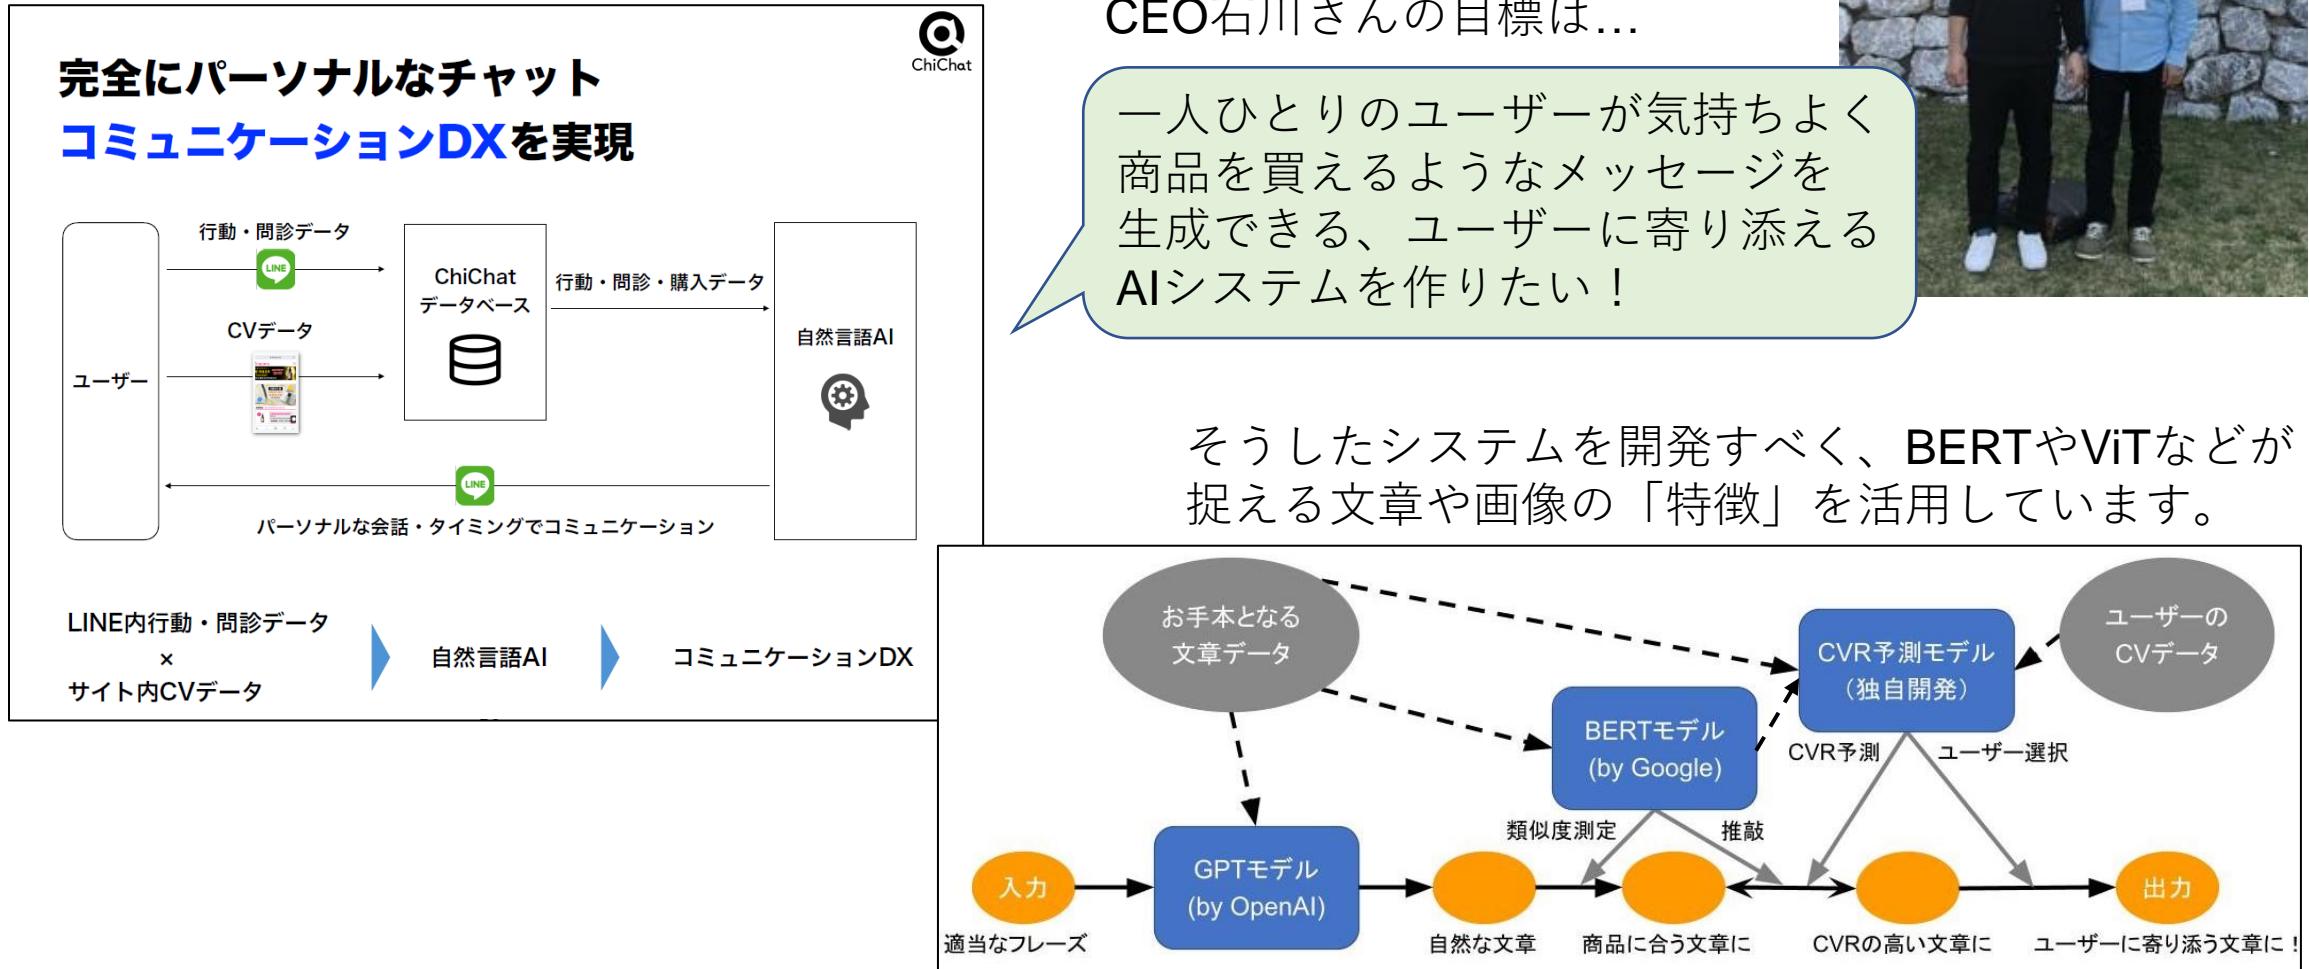
[https://youtu.be/wP0RAWF6\\_h0](https://youtu.be/wP0RAWF6_h0)



Brain area related to "poetic or not":  
Precuneus, ventromedial PFC,  
left temporoparietal junction, ...

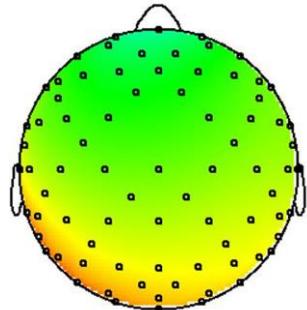
# 研究2：チャットコマースにおける文章・画像の自動生成

(株式会社人々との共同研究、2020年から)



## 研究3：脳活動を統合的に理解する研究（脳活動データ間の変換）

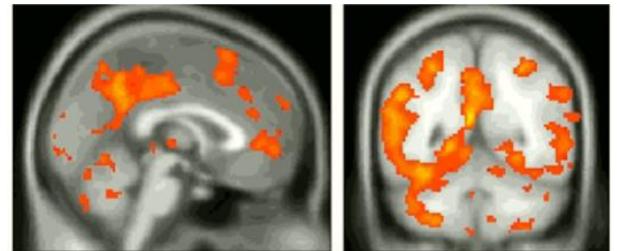
（株式会社アラヤでの研究、ムーンショットプロジェクト、2022年から）



脳波測定 (EEG) のデータ：  
時間分解能は良いが、空間分解能は悪い。  
脳の深いところはよく見えない。



fMRI測定のデータ：  
空間分解能は良いが、時間分解能は悪い。  
脳の深いところまでよく見える。



機械学習で両方の「特徴」を捉えた上で、  
相互に変換する技術を目指します。

MLPhyS 学術変革領域研究(A) 学習物理学の創成  
Foundation of "Machine Learning Physics"

CONTACT Members only En Jp

領域概要 研究組織 イベント 成果 アウトリーチ

計画研究 B03

機械学習への位相幾何学的アプローチ

研究代表者	福嶋 健二	東京大学 理学系研究科
研究分担者	船井 正太郎 (柴正太郎)	沖縄科学技術大学院大学 物理生物学ユニット
	塙崎 謙	京都大学 基礎物理学研究所
	三角 樹弘	近畿大学 理工学部

お誘いいただき  
有難うございます！

## 研究4：学習物理学の研究

（学術変革Aでの研究、2022年から）

物理学で多用される概念の中で、主にトポロジーを使って、機械学習の新しい側面を見出していく  
たいと思っています。

その土台となるかもしれない研究として…

# つまり... 「特徴」 って何だろうか？

今日のテーマ：イジング模型におけるスピン配位の特徴抽出

- 物理学の概念（特に繰り込み）を使って「特徴」が議論できそう！
- イジング模型のハミルトニアン（1次元または2次元の正方格子を考える）

$$\mathcal{H} = -J \sum_{\langle ij \rangle} s_i s_j - H \sum_i s_i$$

- 様々な温度におけるスピン配位（他のパラメータは固定:  $J = 1, H = 0$ ; 白:  $s_i = 1$ , 黒:  $s_i = -1$ ）



T=0.0



2.0



4.0



6.0



8.0

...

相転移点  $T = T_c = 2.27$

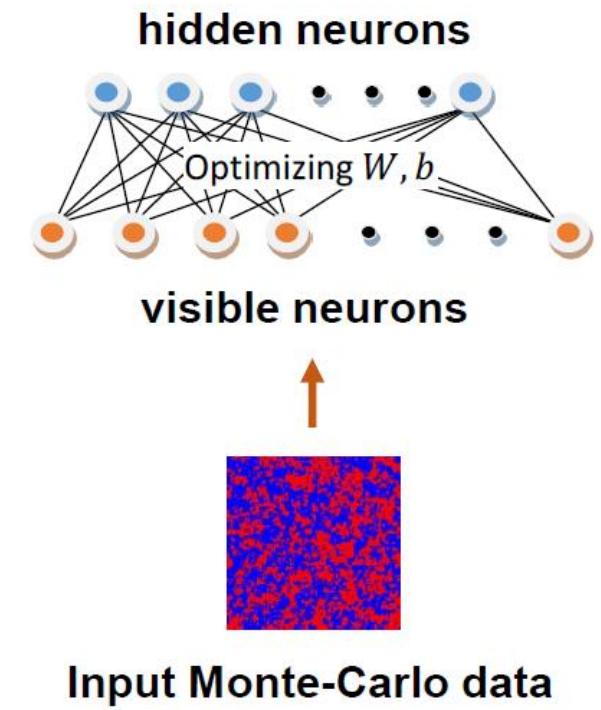
## ➤ 入力データ (不思議に感じるかもしれません...)

[Iso-SSF-Yokoo, '18] [SSF-Giataganas, '18]

- スピン配位を Metropolis Monte Carlo シミュレーションで生成する。
- 入力データには、一定の間隔をもつ様々な温度（や外場  $H$ ）のスピン配位が同じ数だけ含まれるようにする。例えば、 $T = 0, 0.1, 0.2, \dots, 9.9$  (100個の温度) を1000枚ずつ。
- このデータセットは物理系としては不自然なものだが、入力データに画像として様々なパターンが含まれるように選んだ。
- こうして入力データが決まれば、スピン配位の確率分布が定義できて、計算ができる。

## ➤ 機械学習には制限ボルツマンマシン (RBM) を使う

- 入力データと同じ確率分布でデータを出力するように学習をする、ニューラルネットワークである。
- 学習の過程で、RBM は入力データの「特徴」を抽出する。



- 出力データの**確率分布**を、ニューラルネットワークの言葉で定義する必要があるが、RBMではvisible, hidden ニューロンの値を用いて「エネルギー」関数を定義した上で

$$E(\{v_i\}, \{h_a\}) = \sum_{i,a} v_i w_{ia} h_a + \sum_a b_a h_a + \sum_i c_i v_i$$

weights  $w_{ia}$ , bias  $b_a, c_i$

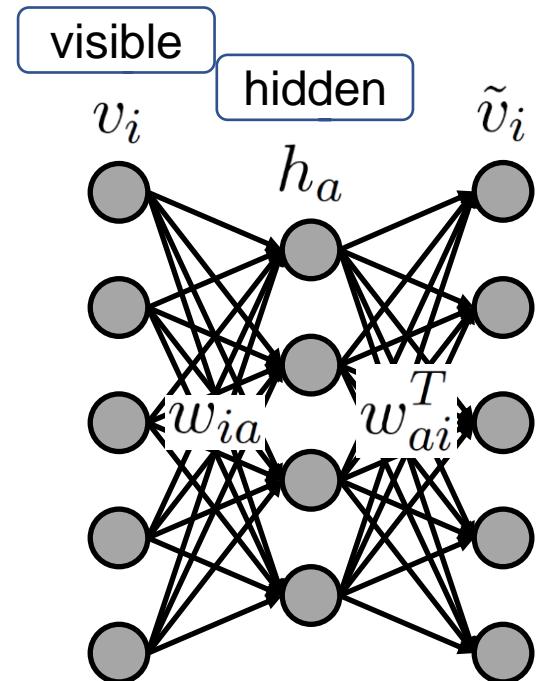
**Boltzmann 分布**によって確率分布を定義する。

$$p(\{h_a\}) = \sum_{\{v_i\}} \frac{e^{-E(\{v_i\}, \{h_a\})}}{\mathcal{Z}}, \quad \tilde{p}(\{\tilde{v}_i\}) = \sum_{\{h_a\}} \frac{e^{-E(\{\tilde{v}_i\}, \{h_a\})}}{\mathcal{Z}}$$

- RBMを訓練する (=weightsとbiasを最適化する) ときには、入力データと出力データの確率分布の **KL divergence** が極小 (local minimum) に近づくようにする。

Loss function:

$$\sum_{\{v_i\}} q(\{v_i\}) \log \frac{q(\{v_i\})}{\tilde{p}(\{v_i\})}$$

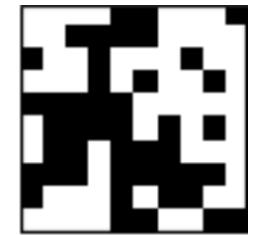


- この **KL divergence** は2つの確率分布の「距離」のようなものである。

$$\sum_{\{v_i\}} q(\{v_i\}) \log \frac{q(\{v_i\})}{\tilde{p}(\{v_i\})}$$

↑  
入力が  $v_i$  である確率 / 出力が  $v_i$  である確率

- 我々の研究では、**入力データ**はスピン配位（白黒）なので  $v_i = \pm 1$  に限られる。また、**hidden** ニューロンの値も **binary** ( $h_a = \pm 1$ ) のみに限定する。
- すると、**hidden** ニューロンと（再構成したときの）**visible** ニューロンの期待値は、Boltzmann 分布を用いて計算できる。



$$\langle h_a \rangle = \tanh \left( \sum_i v_i w_{ia} + b_a \right), \quad \langle \tilde{v}_i \rangle = \tanh \left( \sum_a h_a w_{ai}^T + c_i \right)$$

- 出力**（再構成された）データも当然、 $\tilde{v}_i = \pm 1$  に限定したい。そのために、配位の各スピンの期待値  $\langle \tilde{v}_i \rangle$  を確率  $(1 \pm \langle \tilde{v}_i \rangle)/2$  で、 $\tilde{v}_i = \pm 1$  に置き換える。

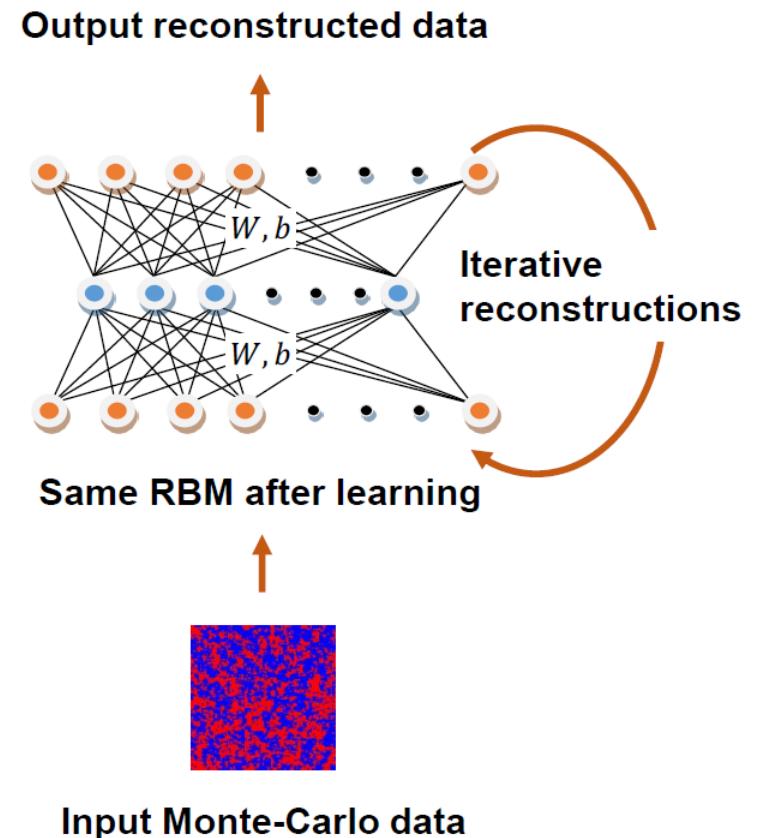
期待値を変えない操作

- 訓練が終わると、入力データの確率分布  $q(\{v_i\})$  と出力データの確率分布  $\tilde{p}(\{v_i\})$  は似ているけれども少し違うものになる（現実的には KL divergence は0にならないため）。
- この出力データを再び入力すると、また少し違う確率分布  $\tilde{p}(\{v_i\})$  の配位データが出力（再構成）される。
- この操作を繰り返し行うと、スピン配位の確率分布の flow が得られる： $q(\{v_i\}) \rightarrow \tilde{p}(\{v_i\}) \rightarrow \tilde{p}(\{v_i\}) \rightarrow \dots$
- これを RBM flow と名付けた。

[Iso-SSF-Yokoo, '18]

➤ いろいろ素朴な疑問が湧いてくると思います

- この RBM flow はイジング模型の RG (繰り込み群) flow と対応するか？ (どちらも特徴的でない情報が欠落する flow のはず)
- もし RBM flow が固定点を持ったら、それは「特徴」そのものを表現するか？ (RBM flow に沿って特徴が強調されるはず)

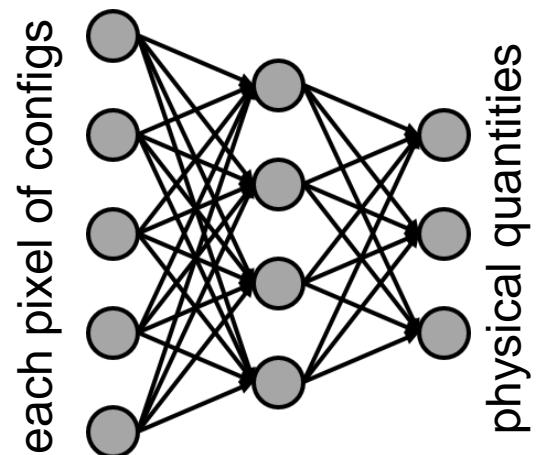


# 我々の結果を眺めてみよう

[Iso-SSF-Yokoo, '18]  
[SSF-Giataganas, '18]

- **RBM flow** はパラメータ  $(T, H)$  の空間に固定点を持つ！
- スピン配位の固定点は存在しない。従って、RBM flow の固定点  $(T, H)$  における新しい配位を作り続けることになる。
- 出力データ（配位）の  $(T, H)$  を見積もるために、我々は2つの方法を使った。
  1. 別のニューラルネットワークを訓練して、入力データの正しい  $(T, H)$  を出力できるようにする。（教師あり学習）  

MMC シミュレーションのパラメータ
  2. 外場なし ( $H = 0$ ) の配位のみを扱う場合は、ハミルトニアンでエネルギーを計算して、温度  $T$  を見積もることができる。  
(1の方法と矛盾しない結果が得られる。)

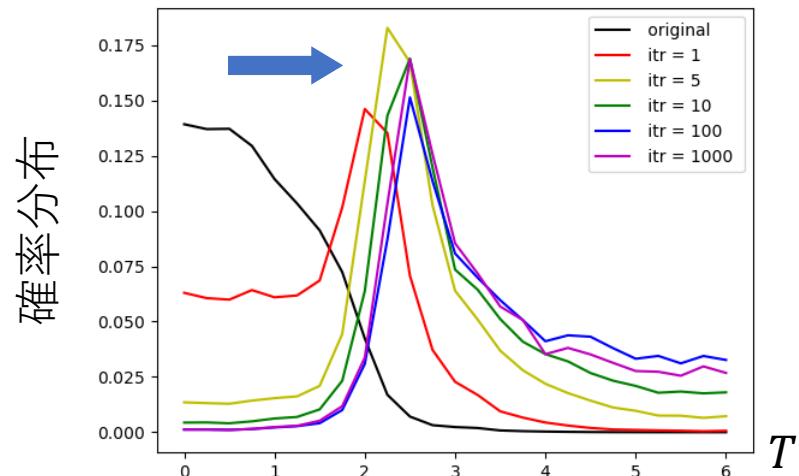


➤ RBM flow と RG flow の振る舞いは異なる！

[Iso-SSF-Yokoo, '18]

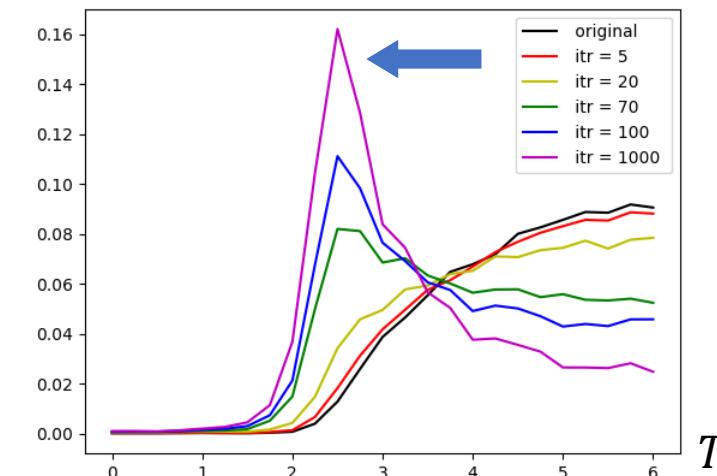
- RBM flow は相転移点  $T = T_c \sim 2.27$  に近づいていく、 $T = 0, \infty$  から遠ざかっていく。  
これは RG (繰り込み群) flow とちょうど逆の方向になっている。

2d, H=0



$n_h = 81$

T=0 (低温) の配位から再構成した場合

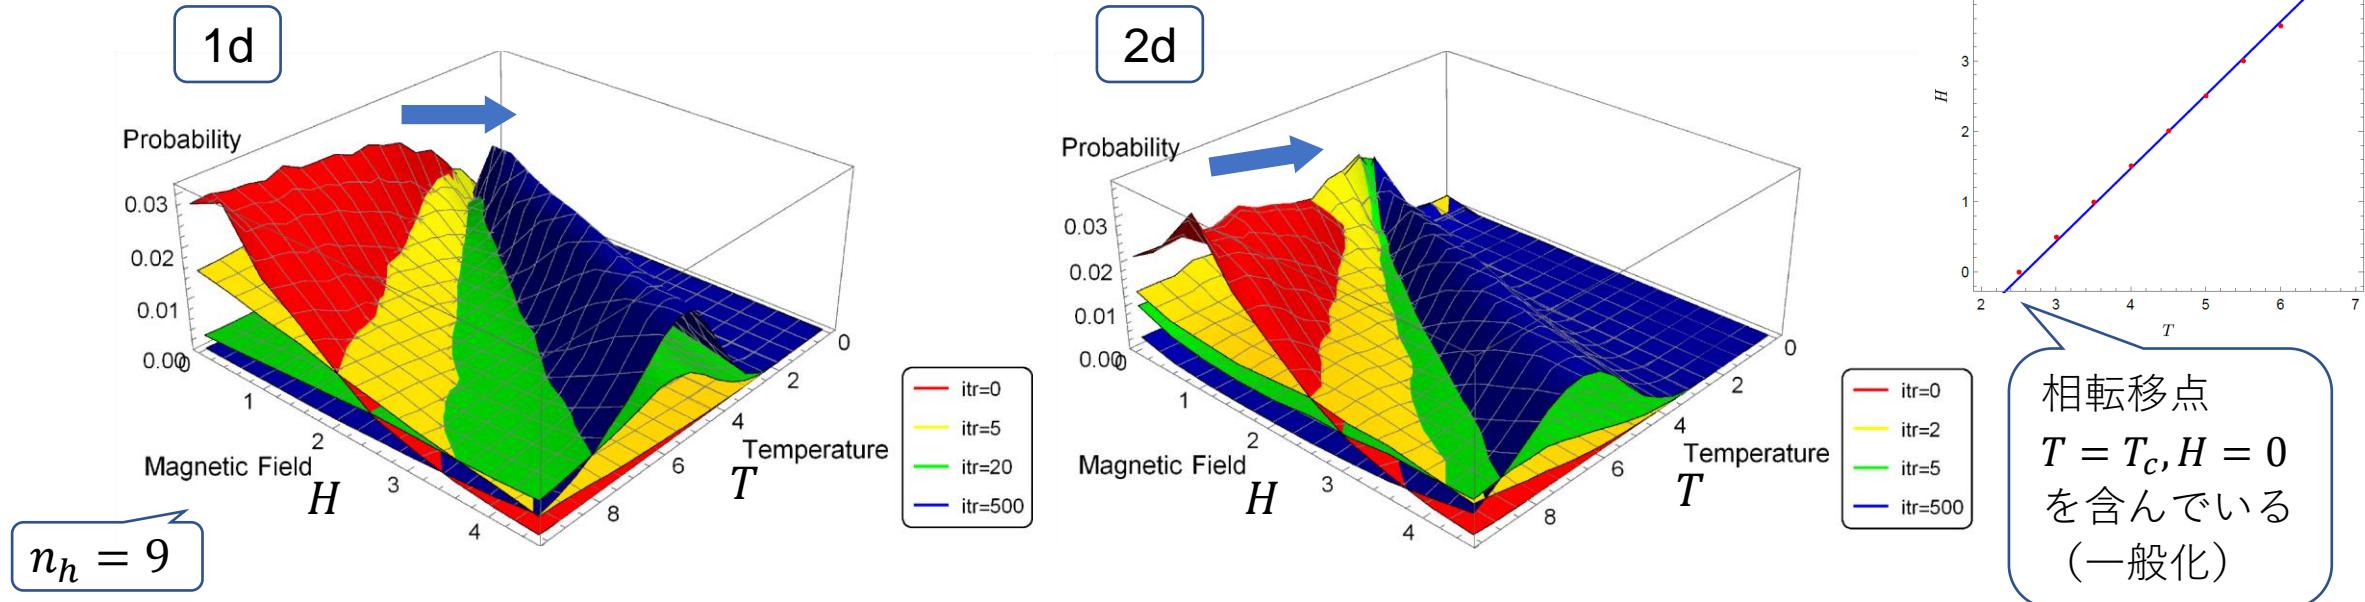


T=6 (高温) の配位から再構成した場合

- Data: configs in 10x10 lattice, 1000 configs at each  $T=0, 0.25, \dots, 6, H=0$ .  
(Same results when  $T=0, 0.25, \dots, 10 / T=0, 0.25, \dots, 2$  and  $4, 4.25, \dots, 6$ .)
- RBM hyperparameters:  $n_v = 100, n_h \leq n_v$ , learning rate = 0.1, epoch = 5000

➤ 1次元と2次元のスピン配位で外場あり ( $H \neq 0$ ) の場合に一般化 [SSF-Giataganas, '18]

- **RBM flow** は、パラメータ  $(T, H)$  空間で比熱が極大になる点に近づいていく。  
この flow とその固定点は、やはり **RG flow** とは異なる。

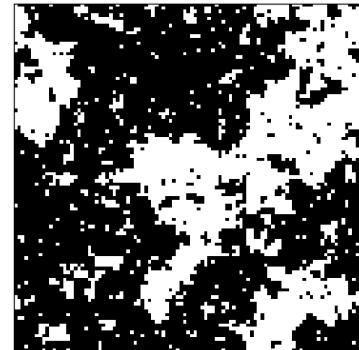


- Data: configs in 100 (1d) or 10x10 (2d) lattice, 1000 configs at each  $(T, H)$ , where  $T=0, 0.5, \dots, 9.5$  and  $H=0, 0.5, \dots, 4.5$ .
- RBM hyperparameters:  $n_v = 100, n_h \leq 16$ , learning rate = 0.001, epoch = 10000

# 面白い結果には見えるけれども…

- 理由がはっきりしない：スケール不变性と関係があるのか？
- 条件がはっきりしない：様々なパラメータ依存性を調べるべき。

なぜ、いつ、RBM flow の固定点は  $T = T_c$  に現れるのだろうか？ ( $H = 0$  の場合)



相転移点における  
スピニ配位は  
スケール不变性をもつ

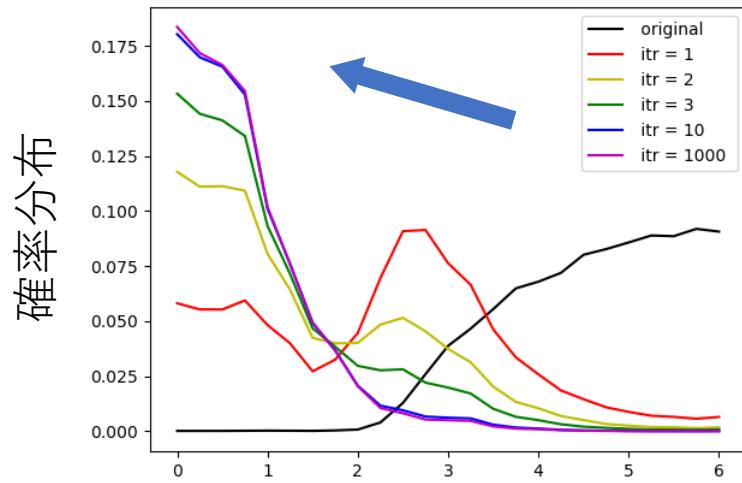
# なぜ？：スケール不変性をもつ証拠

- 次の2つの RBM を作って、RBM flow と weight 行列を解析しよう。  
そして、比較してみよう。

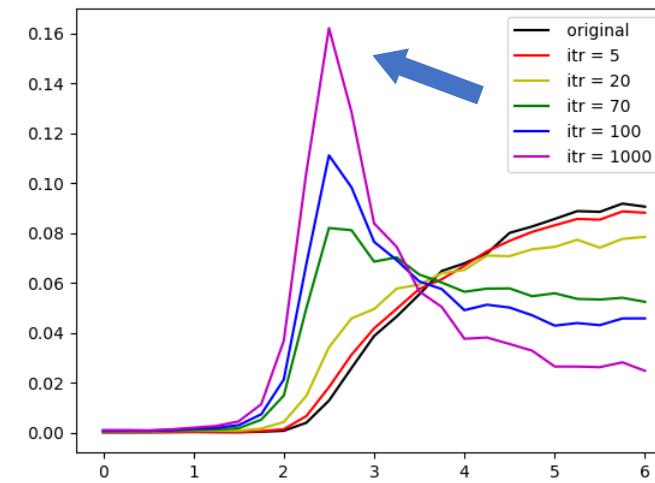
[Iso-SSF-Yokoo, '18]

- 低温の（大きなスケールをもつ）配位のみで訓練した RBM
- 幅広い温度  $T = 0, 0.25, \dots, 6$  の配位で訓練した RBM (先ほどと同じ)

2d, H=0

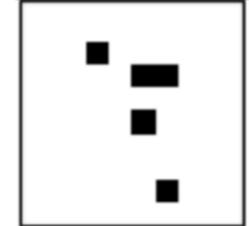


$T=0$ の配位のみを学習した RBM

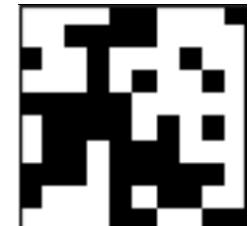


$T=0, \dots, 6$  の配位を学習した RBM

低温



高温



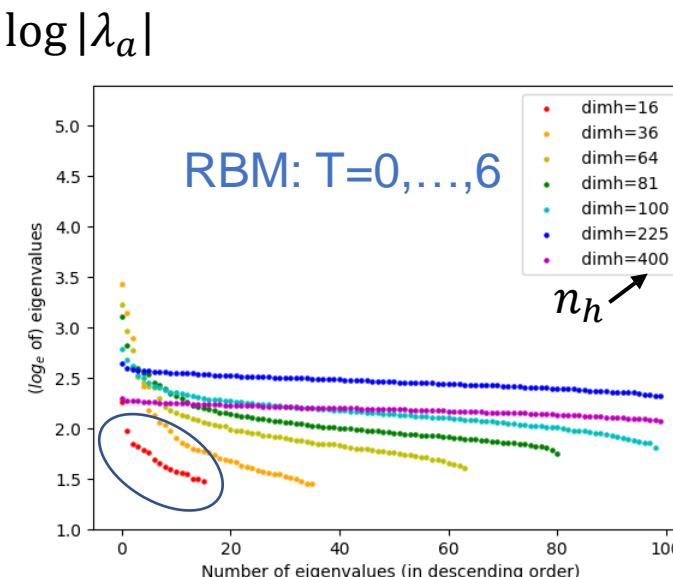
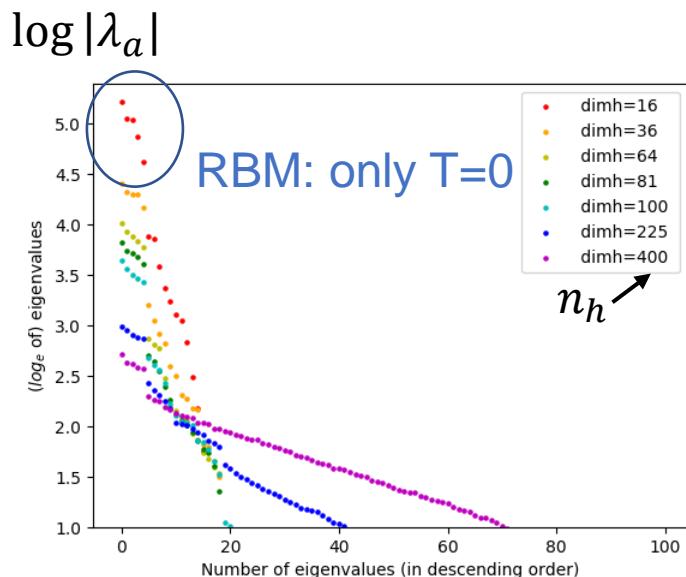
➤ Weight 行列  $\sum_a w_{ia} w_{ja}$  の固有値

Hidden ニューロンの基底に依存しない積を取った

- RBM が低温の配位のみ学習した場合、**少数**（5個）の固有値だけが特に大きくなる。

$$ww^T u_a = \lambda_a u_a$$

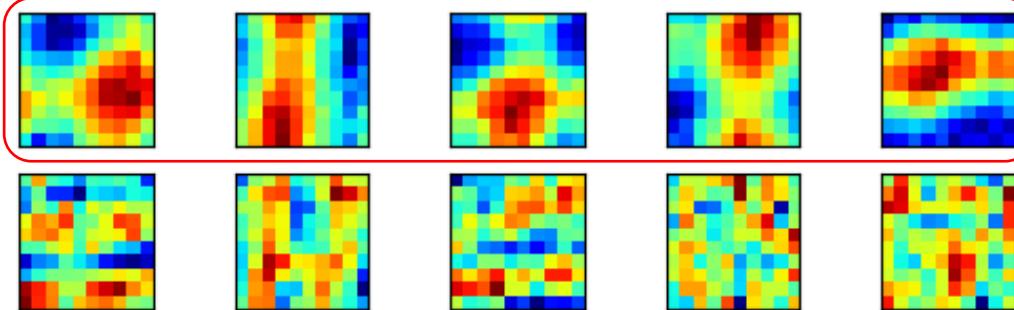
- RBM が様々な温度  $T = 0, 0.25, \dots, 6$ （高温を含む）の配位を学習した場合、**すべての固有値**が似たような値をもつ。  
様々な温度（=様々なスケール）の配位を学習するために、多くの hidden ニューロンが必要になるのだろう。



➤ Weight 行列  $ww^T$  の固有ベクトル

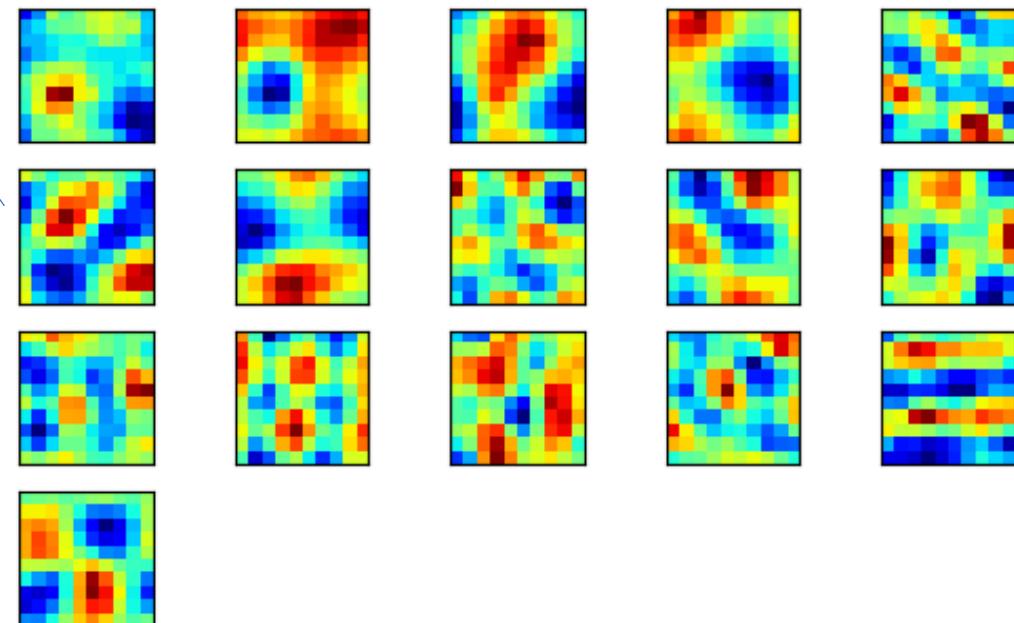
$$ww^T u_a = \lambda_a u_a$$

- 低温の配位のみを学習した RBM ( $T = 0, \dots, 2, n_h = 16$ )



大きなスケールをもつ配位が  
大きな固有値をもつ。

- 様々な温度の配位を学習した RBM ( $T = 0, \dots, 6, n_h = 16$ )



様々なスケールをもつ配位が  
似たような固有値をもつ！

それらすべての配位が出力  
(再構成) データに現れる



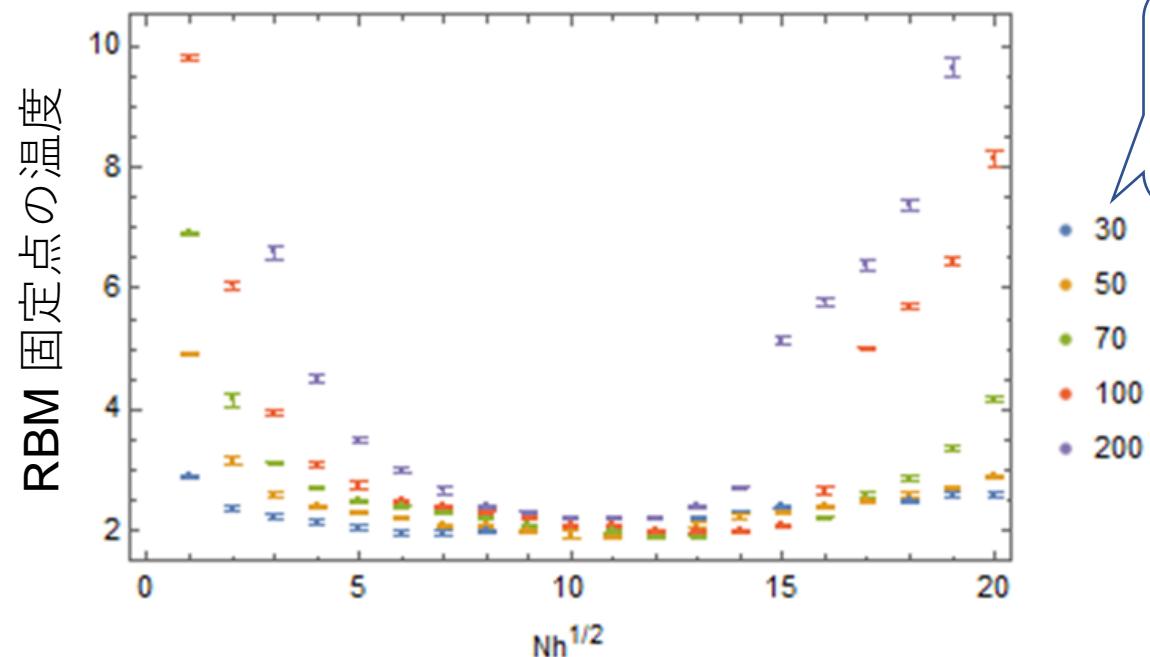
スケール不変性？



# いつ？：RBM 固定点が $T \sim T_c$ に現れる条件

[SSF, '21]

$N_v=20^2$  (visible ニューロンの数 = 配位のサイズ)



2d,  $H=0$

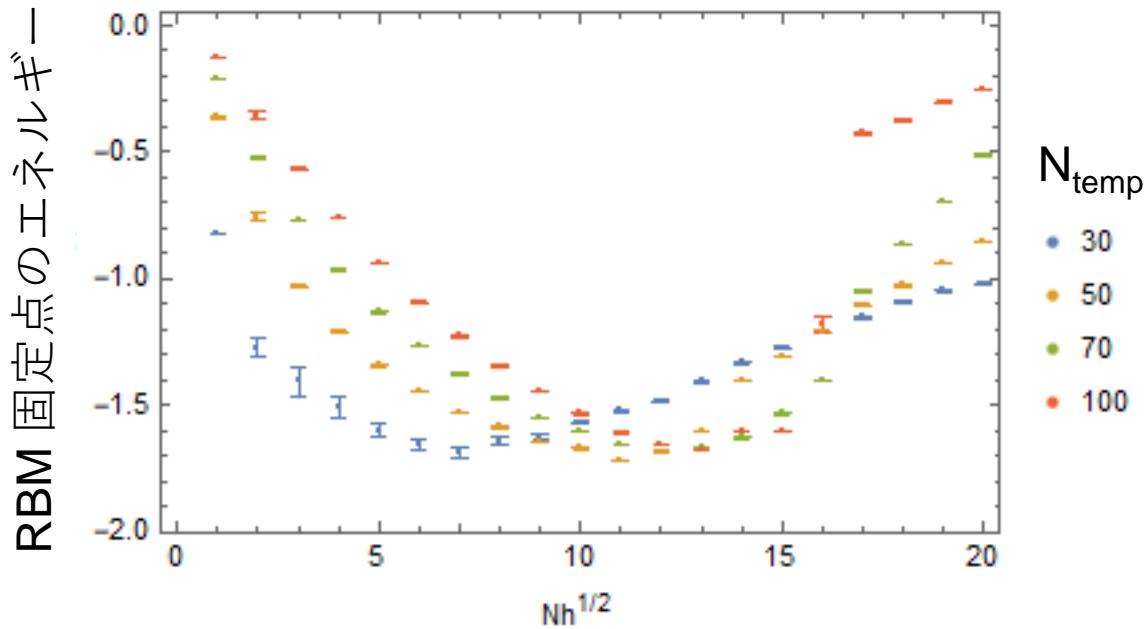
$N_h$ : hidden ニューロンの数

$N_{temp}$ : 学習データに含まれる温度の数  
 $T = 0, 0.1, \dots, 0.1 \times (N_{temp} - 1)$  の配位が同数ずつ（外場なし）。

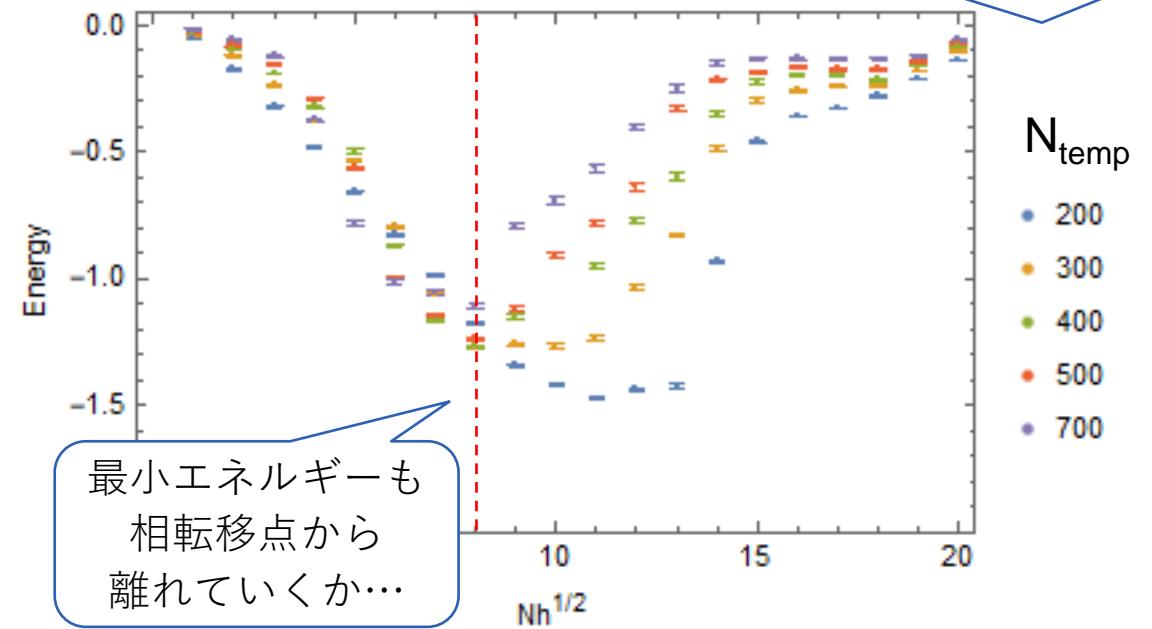
$N_h/N_v \sim 1/4$  の辺りで  
RBM 固定点の温度が最低になり、  
その温度が  $T \sim T_c$  になるようだ。

温度の代わりにエネルギーを使って、さらに詳しく結果を見よう。  
 (エネルギーは  $T \sim T_c$  で大きく変化するため)

$Nv=20^2$



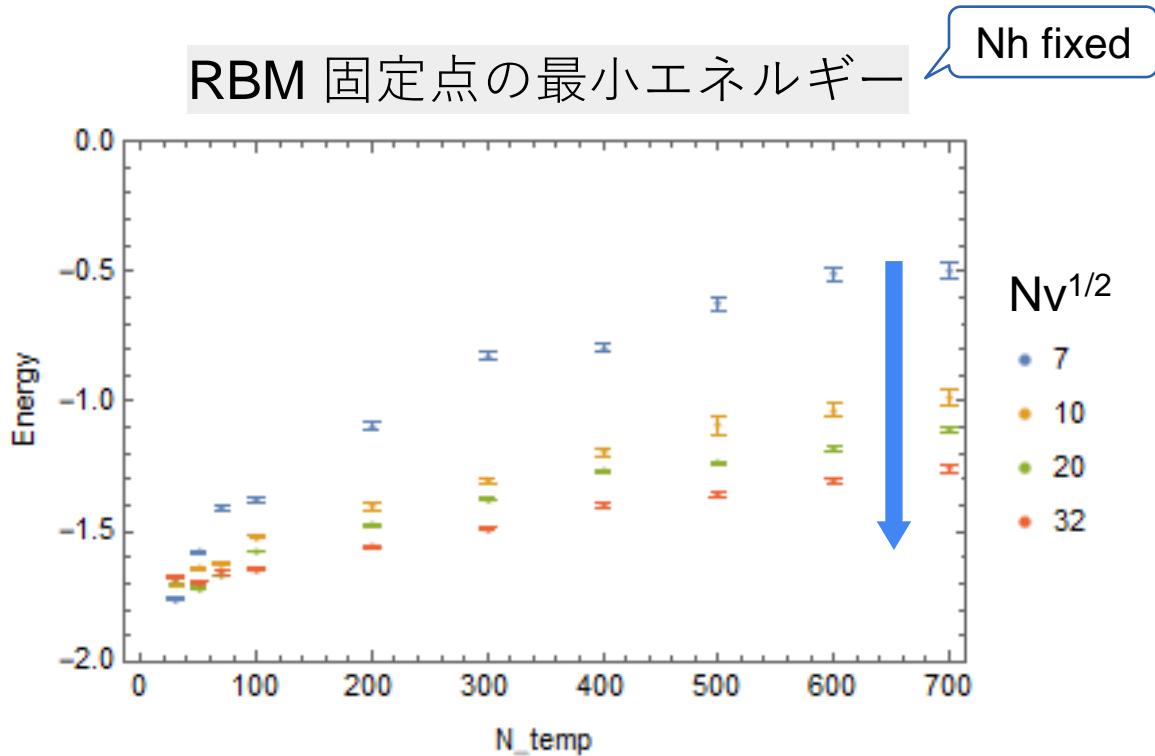
$Nv=20^2$



RBM 固定点のエネルギーが最小となる  $Nh$  は、 $N_{temp}$  (温度の範囲) に依存して変化する。  
 特に  $N_{temp}$  が大きくなると、エネルギーが最小となる  $Nh$  は  $Nh/Nv \sim 0.4^2$  に収束するようだ。

ここから先は、エネルギーが“最小”となる  $Nh=(integer)^2$  のみに注目しよう。

スピン配位のサイズが大きくなれば、 $N_{\text{temp}}$  が大きくなっても、RBM 固定点の最小エネルギーは相転移点から離れにくくなる（よりゆっくり上昇する）。

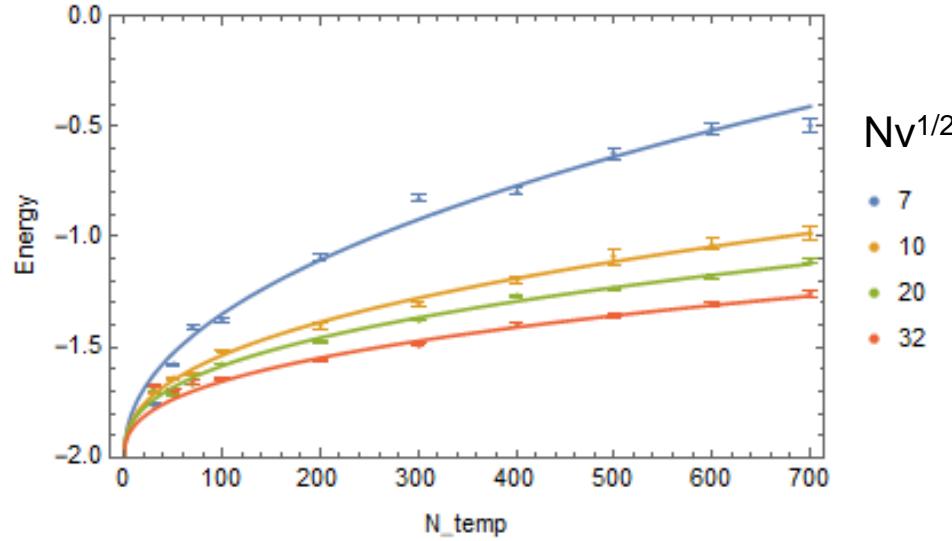


Nv: visible ニューロンの数 = 配位のサイズ  
 $N_{\text{temp}}$ : 学習データに含まれる配位の温度は  
 $T = 0, 0.1, \dots, 0.1 \times (N_{\text{temp}} - 1)$

このプロットから推測できることは…

- ✓  $N_{\text{temp}} \rightarrow \infty, Nv: \text{fixed}$  の場合：  
RBM 固定点は  $E \sim 0, T \rightarrow \infty$  になる。
- ✓  $N_{\text{temp}}: \text{fixed}, Nv \rightarrow \infty$  の場合：  
RBM 固定点は低温に向かうが、 $T \neq 0$  の有限温度で収束するだろう。  
小さい  $N_{\text{temp}} < 100$  の領域で、固定点は  $E \sim -1.7, T \sim T_c$  であることを考えれば、収束する温度は  $T \sim T_c$  になるだろう。

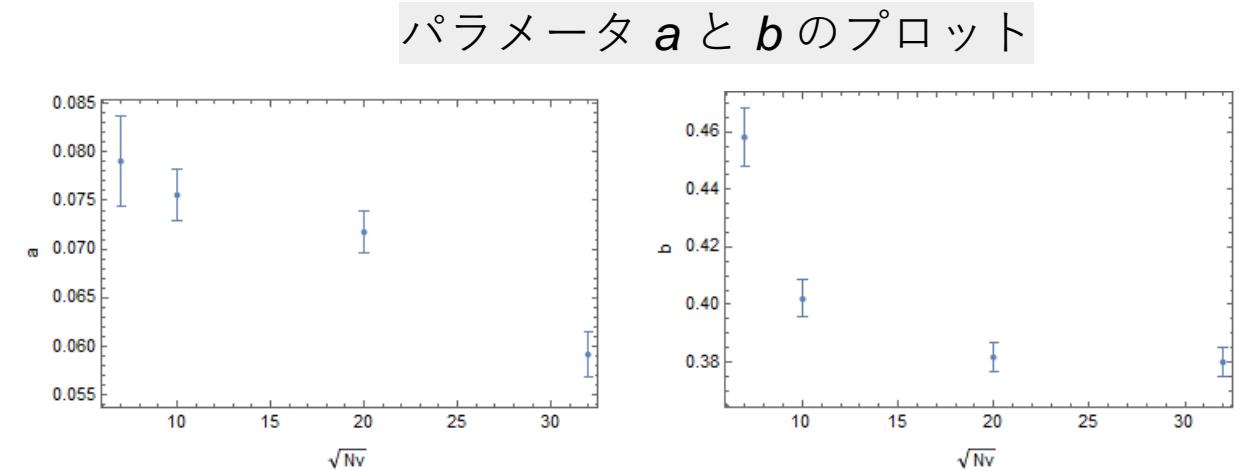
参考までに、これらの RBM 固定点を  $\boxed{\text{Energy} = -2 + a N_{temp}^b}$  で fitting すると、かなりきれいに fit できてる...



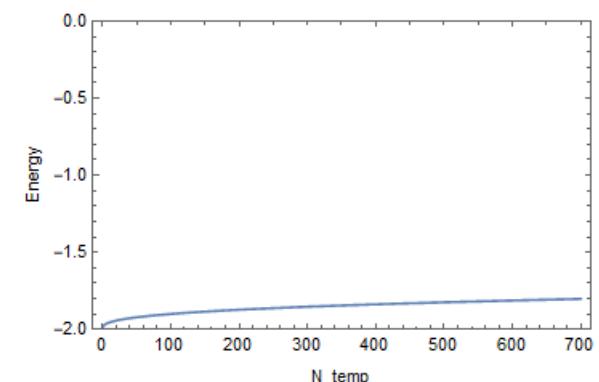
$(N_{temp} \geq 100$  の点のみ fitting に使った)

以上の議論に基づいて、私は次の仮説を提案します！

$N_{temp}$  が大きくても固定されていれば、 $Nv$  を充分に大きくすると、RBM 固定点は  $T \sim T_c$  に現れるだろう。

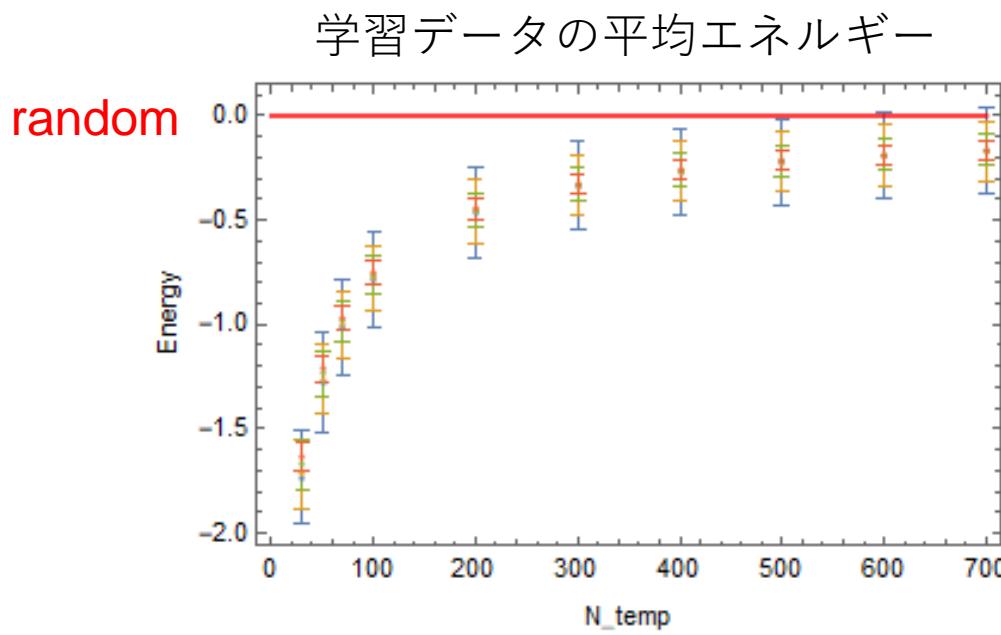


$Nv$  が大きくなると、パラメータ  $a, b$  はどちらも減少する。従って、 $N_{temp}$  vs. energy のプロットは  $Nv \rightarrow \infty$  の極限でよりフラットになるだろう。

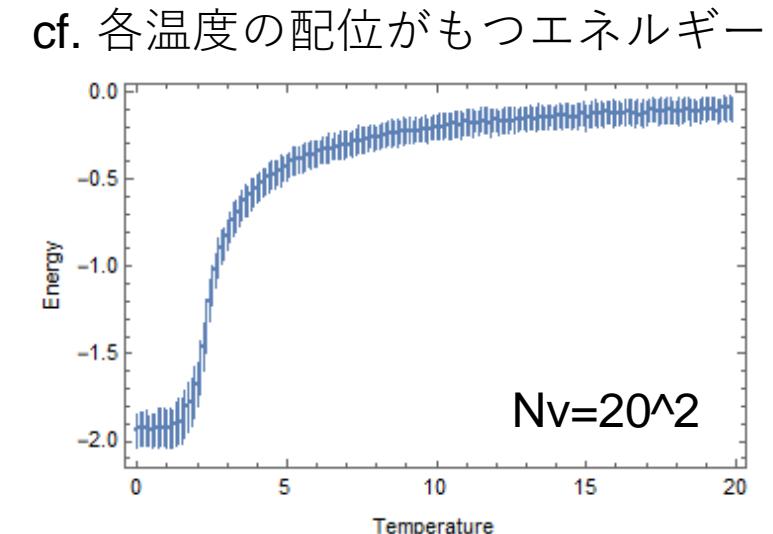


$Nv$  を大きくすると RBM 固定点のエネルギーが小さくなる理由は...

- 学習データに含まれる（完全に）ランダムなスピン配位が少なくなるから。
- ランダムな配位が少なくなれば、RBM はより多くのパターンを学習できる。
- 逆に、もしランダムな配位しかなければ、RBM は何も学習できない。  
(loss function の値を小さくする術がない...)



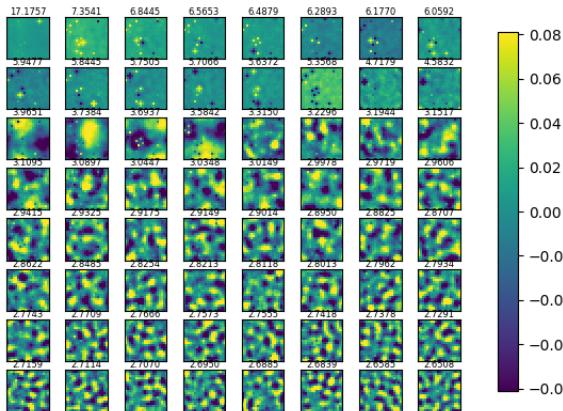
エラーバー ( $1\sigma$ ) を見ると、  
 $Nv$  が大きくなれば、ランダムな  
配位は減ることがわかる。



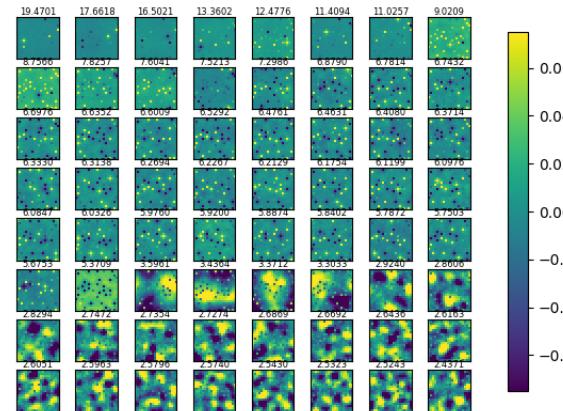
RBM が学習したパターンは weight 行列  $ww^T$  の固有ベクトルの中に見つけられる。

(以下はすべて  $Nv=20^2$ ,  $Nh=8^2$  の結果)

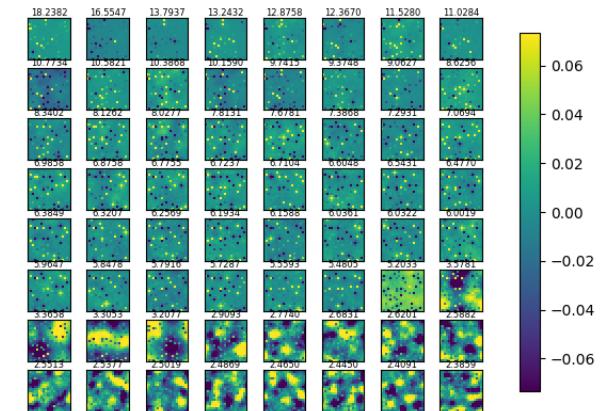
$N_{temp}=200$



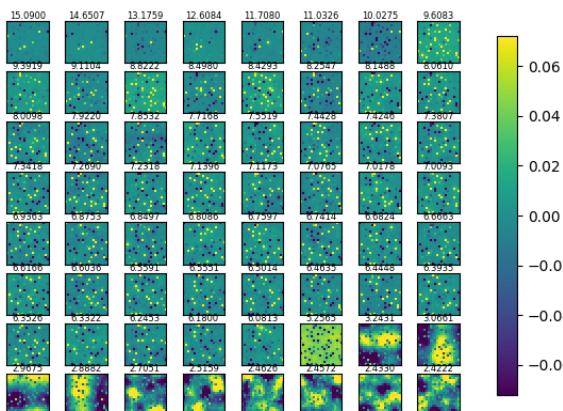
$N_{temp}=300$



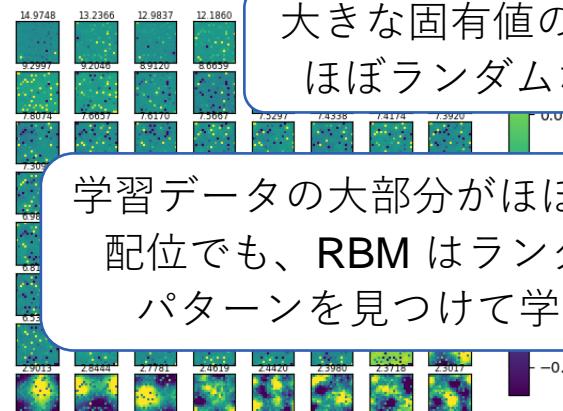
$N_{temp}=400$



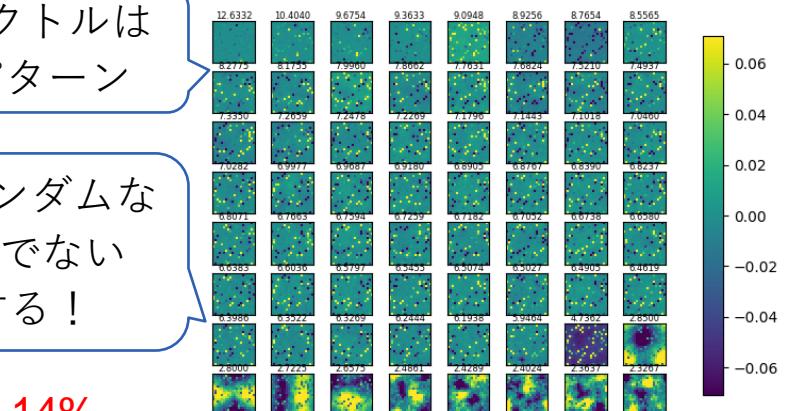
$N_{temp}=500$



$N_{temp}=600$



$N_{temp}=700$



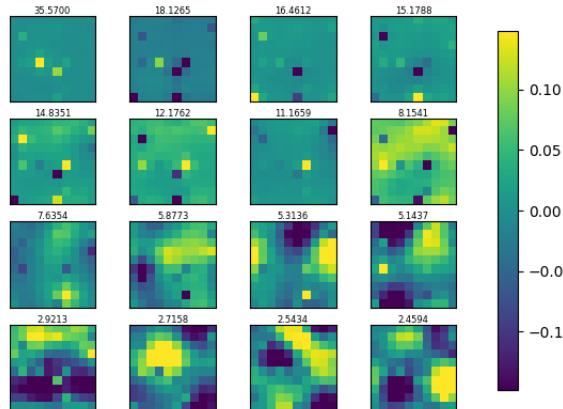
14%

8<sup>2</sup> 個中 9 個の固有ベクトルがランダムでないパターン

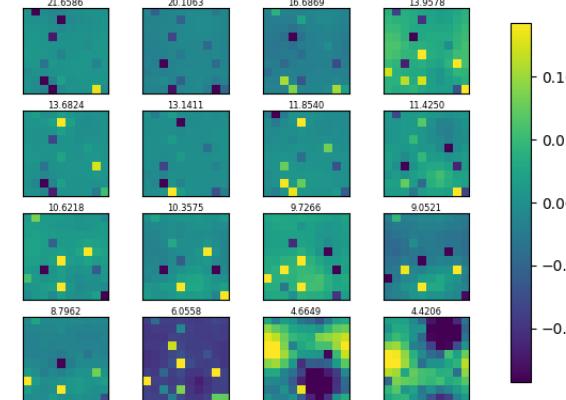
RBM が学習したパターンは weight 行列  $ww^T$  の固有ベクトルの中に見つけられる。

(以下はすべて  $Nv=10^2$ ,  $Nh=4^2$  の結果)

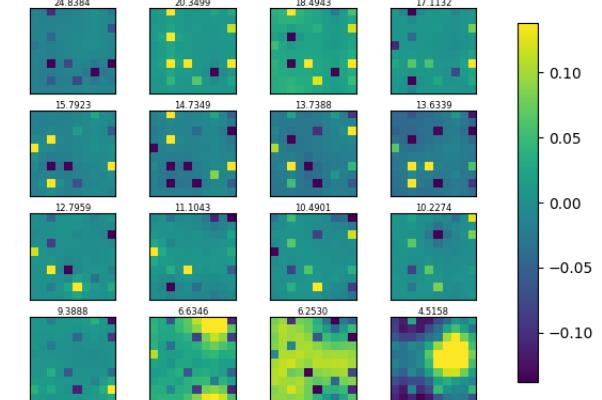
$N_{temp}=200$



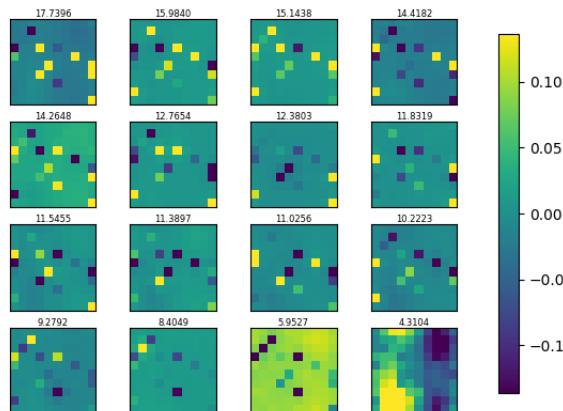
$N_{temp}=300$



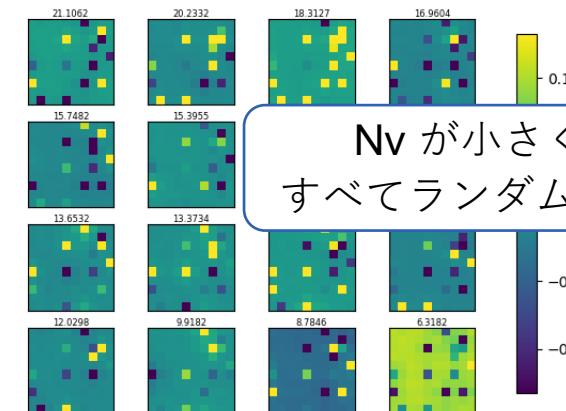
$N_{temp}=400$



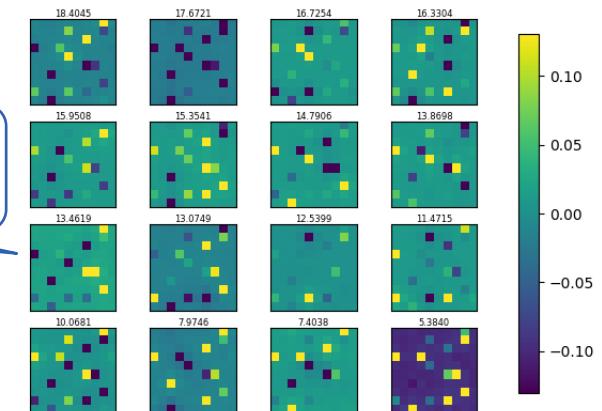
$N_{temp}=500$



$N_{temp}=600$



$N_{temp}=700$



$Nv$  が小さくなると  
すべてランダムなパターン

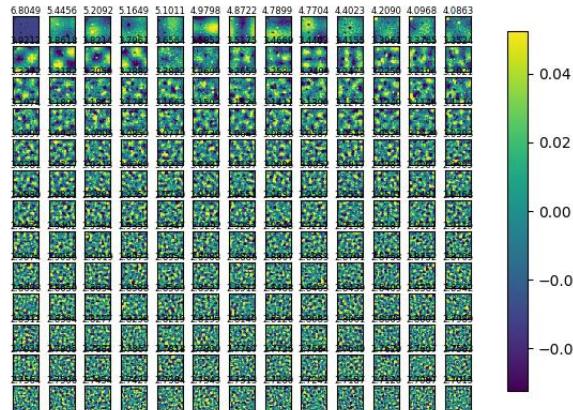
0%

0個の固有ベクトルがランダムでないパターン

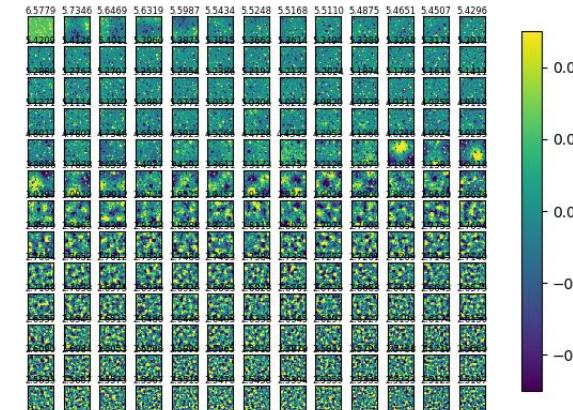
RBM が学習したパターンは weight 行列  $ww^T$  の固有ベクトルの中に見つけられる。

(以下はすべて  $Nv=32^2$ ,  $Nh=13^2$  の結果)

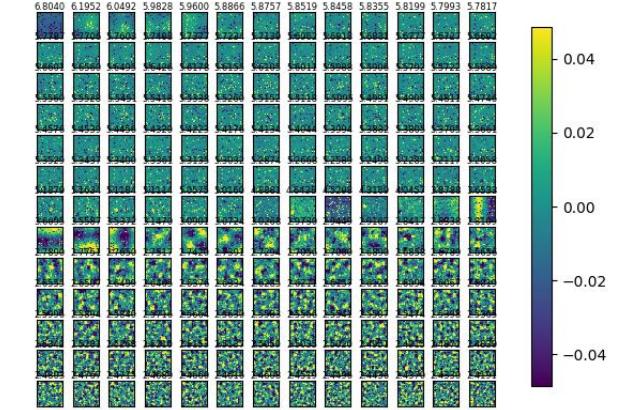
$N_{temp}=200$



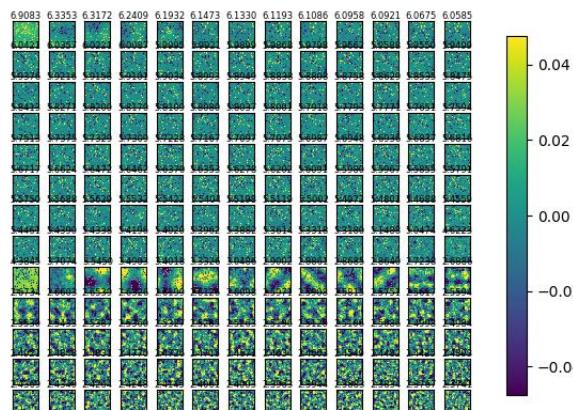
$N_{temp}=300$



$N_{temp}=400$



$N_{temp}=500$



$N_{temp}=600$



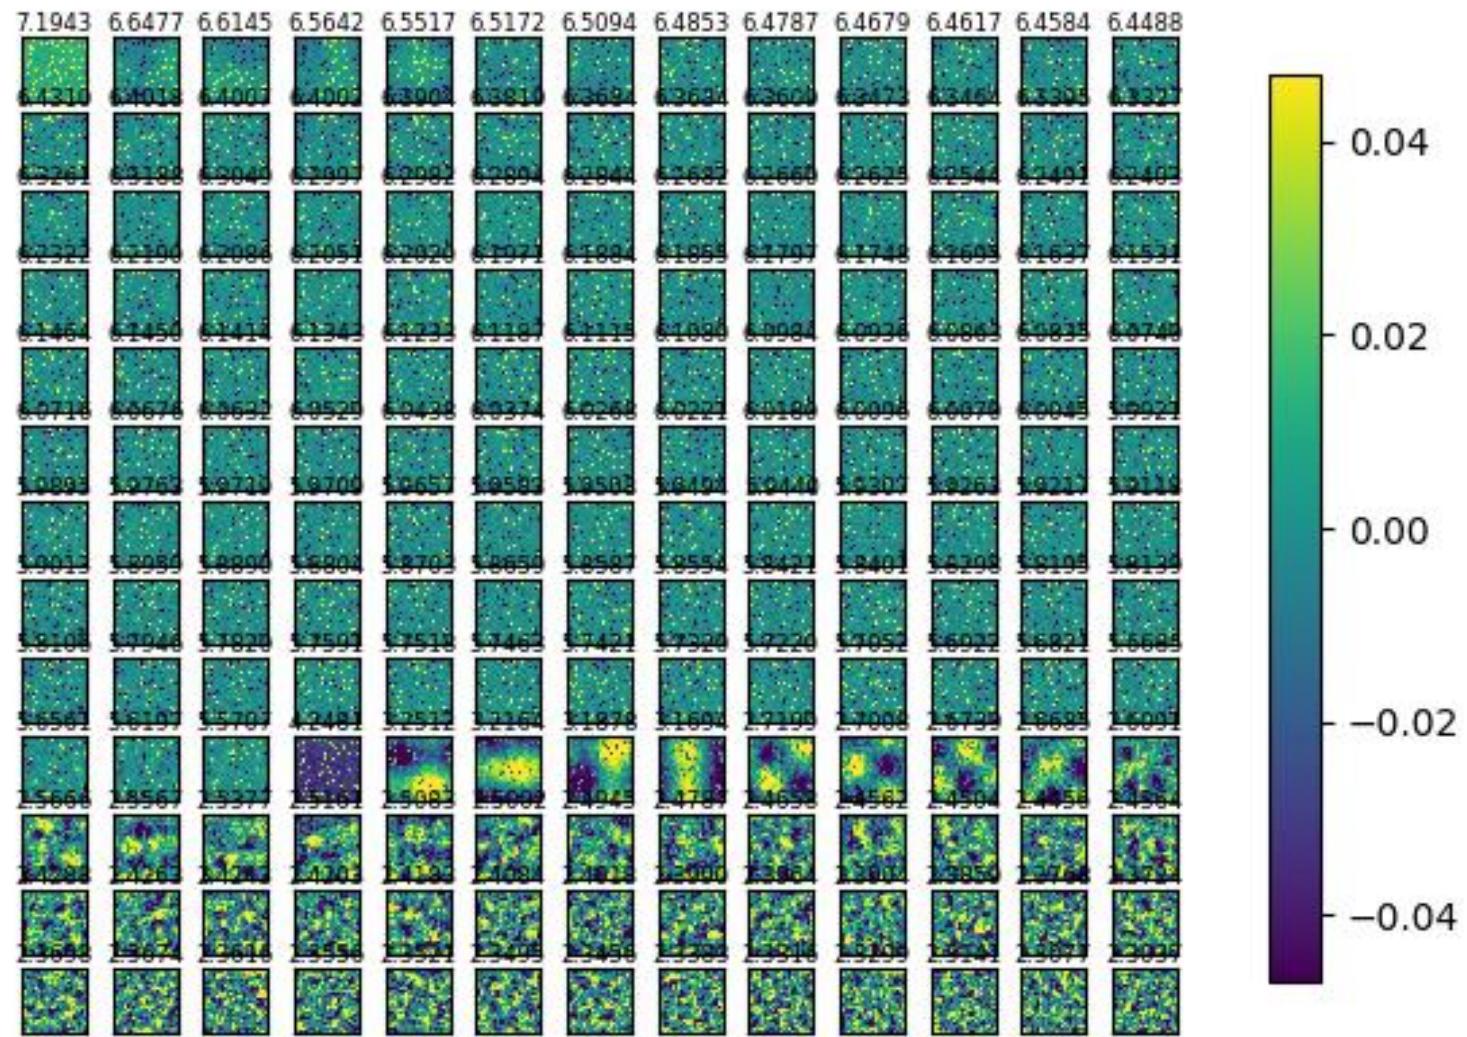
28%

13<sup>2</sup> 個中 48 個の固有ベクトルがランダムでないパターン

$$Nv=32^2,$$

Nh=13^2,

N\_temp=700



# 結論として

- イジング模型のスピン配位がもつ特徴を抽出するために、RBM の機械学習を行った。
- 配位の再構成によって得られる RBM flow は固定点 (= 特徴) をもつ。この点は RG flow と似ているが、flow の振る舞いは明らかに異なる。
- このとき RBM が掴んだ特徴は（相転移点において配位がもつ）スケール不变性であろうと、我々は提案した。
- さらに、RBM flow の固定点が相転移点に現れるために満たすべき条件 ( $N_{\text{temp}}$  は固定した上で、配位のサイズを充分大きくする) も提案した。