

深層学習と物理学

橋本幸士（阪大理）



[View On GitHub](#)

Deep learning and Physics 2020

Project maintained by [cometscome](#)

Hosted on GitHub Pages — Theme by [mattgraham](#)

「ディープラーニングと物理学2020 オンライン」とはオンラインWeb会議システムを利用したセミナーです。

世話人: 橋本幸士 (大阪大)、富谷昭夫 (理研BNL)、永井佑紀 (原子力機構)、田中章詞 (理研iTHEMS) (順不同)


- » 第19回: James Halverson 「Neural Networks and Quantum Field Theory」 1/28
- » 第18回: 鈴木大慈 「無限次元勾配ランジュバン動力学による深層学習の最適化理論と汎化誤差解析」 1/14
- » 第17回: 本間希樹 「EHTによるブラックホールの撮像とスパースモデリング」 12/10
- » 第16回: 入門講義 「機械学習と物理」 11/26
- » 第15回: 森貴司 「深層学習の汎化の謎をめぐって」 11/12
- » 第14回: 野尻美保子 「ミンコフスキー汎関数を用いた機械学習の提案」 10/29
- » 第13回: Kazuhiro Terao 「End-to-End, Machine Learning-based Data Reconstruction for Particle Imaging Neutrino Detectors」 10/15 (ご講演は英語)
- » 第12回: 樺島祥介 「スパース線形回帰に対する半解析的ブートストラップ法」 10/1
- » 第11回: 藤井啓祐 「NISQ (Noisy Intermediate-Scale Quantum technology) マシンを用いた量子機械学習」 9/17
- » 第10回: 斎藤弘樹 「強化学習を用いたボース・アインシュタイン凝縮体の制御」 9/3
- » 第9回: 林祐輔 「表現学習の熱力学: 深層生成モデルの物理法則を求めて」 8/20
- » 第8回: 野村悠祐 「ボルツマンマシンを用いた量子多体波動関数表現: 深層ボルツマンマシンによる厳密な表現と制限ボルツマンマシンによる数値的近似表現」 8/6
- » 第7回: 本武陽一 「物理学者と学習機械の効果的な協業に向けて: 学習済み深層ニューラルネットワークからの解釈可能な物理法則抽出」 7/30
- » 第6回: 吉岡信行 「ニューラルネットワークで探る量子多体系の表現」 7/9
- » 第5回: 福嶋健二 「物理学における観測と機械学習: 中性子星の事例」 6/25
- » 第4回: 唐木田亮 「深層学習の数理: 統計力学的アプローチ」 6/11
- » 第3回: ライトニングトーク 6/11



富谷昭夫さん(理研BNL)



永井佑紀さん(原子力機構)



田中章詞さん(理研iTHEMS)



Physics \cap ML

a virtual hub at the interface of theoretical physics and deep learning.

06

May 2020

Natural Graph Networks

Taco Cohen, Qualcomm AI Research, 12:00 EDT

20

May 2020

Building symmetries into generative flow models

Phiala Shanahan, MIT, 12:00 EDT

03

Jun 2020

Why do neural networks generalise in the overparameterised regime?

Ard Louis, University of Oxford, 12:00 EDT

17

Jun 2020

Deep Learning and Quantum Gravity

Koji Hashimoto, Osaka University, 12:00 EDT

[← Prev page](#)

For link and password to the talks, please sign up for the [Physics \$\cap\$ ML mailing list](#).
Videos may be found on [our YouTube channel](#) and slides by clicking on past talk titles.



16日 K406会場 16pK406 13:30~17:25

素粒子論領域, 理論核物理領域, 宇宙線・宇宙物理領域, 領域3, 領域4, 領域8, 領域11
機械学習と物理

- 1 (一般シンポジウム講演) はじめに
阪大理・物理
橋本幸士
- 2 (一般シンポジウム講演) 物性物理のグランドチャレンジに対する重回帰分析と機械学習
東大院工
今田正俊
- 3 (一般シンポジウム講演) 強い相互作用の最難問 — 中性子星の状態方程式
東大理・物理・原子核理論
福岡健二

休憩 (14:35~14:45)

- 4 (一般シンポジウム講演) データ駆動手法による相関物質の予測と理解
産総研 CD-FMat
三宅隆
- 5 (一般シンポジウム講演) 機械学習によるマルコフ連鎖モンテカルロ法の高速度化へ向けて
理研(AIP/iTHEMS), 慶應大・数理
田中章詞

休憩 (15:45~15:55)

- 6 (一般シンポジウム講演) 機械学習による特徴抽出と、繰り込み群や熱力学との関係
OIST
船井正太郎
- 7 (一般シンポジウム講演) 広域撮像宇宙サーベイによるビッグデータ宇宙論
東大理・物理・宇宙理論
吉田直紀
- 8 (一般シンポジウム講演) 量子力学と機械学習の数理
東北大院情報科学
大関真之

Deep Learning And Physics

DLAP2019

> Yukawa Institute for Theoretical Physics
> Kyoto, Japan
> 31 Oct - 2 Nov 2019 ■

Target scope of Conference

Deep learning plays a central role in recent developments in research in artificial intelligence (AI). Various ideas based on physics are found in the research of deep learning, and consequently, deep learning and physics are related intimately. This international conference is dedicated to (1) applications of deep learning to physics, (2) discovering similarities among deep learning and physics, and (3) leading to new paradigm in physics motivated by deep learning. Researchers in related fields are welcome to attending discussions at the conference.

Organizers

[Koji Hashimoto](#) (Osaka U), [Masatoshi Imada](#) (Toyota RIKEN / Waseda U), [Kouji Kashiwa](#) (Fukuoka Institute of Technology), [Yuki Nagai](#) (JAEA), [Masayuki Ohzeki](#) (Tohoku U), [Enrico Rinaldi](#) (Riken & Arithmer Inc.), [Akinori Tanaka](#) (RIKEN AIP), [Akio Tomiya](#) (Riken BNL)

Date and Place

31 Oct - 2 Nov 2019

Panasonic Auditorium, Yukawa Hall, [Yukawa institute for theoretical physics, Kyoto university](#)

- > Osaka CTSR – RIKEN iTHES/iTHEMS - Kavli IPMU
- > Joint symposium

Deep Learning and physics

- > Venue: Nambu hall, Osaka university
- > Date: June 5 (Mon), 2017, 13:00-18:00
- > Invited speakers :
 - > S. Amari (RIKEN)
 - > S. Ikeda (Kavli IPMU / ISM)
 - > Y. Kawahara (Osaka U. / RIKEN)
 - > M. Taki (RIKEN)
 - > A. Tanaka (RIKEN)
 - > T. Ohtsuki (Sophia U.)
 - > N. Suzuki (Kavli IPMU) ■



- > Organizers:
 - > K. Hashimoto (Osaka U.)
 - > T. Hatsuda (RIKEN iTHES/iTHEMS)
 - > H. Murayama (Kavli IPMU) ■

```
Sherlock:~ $ python
Python 3.6.4 (v3.6.4:d48eacebad5, Dec 18 2017, 21:07:28)
Type "help", "copyright", "credits" or "license()" for more information.
>>> import numpy as np
>>> import chainer
>>> from chainer import Chain
>>> import chainer.functions as F
>>> import chainer.links as L
>>>
>>> class AdS_deep_net(chainer.Chain):
...     def __init__(self, n_units, n_out):
...         super().__init__(
...             L.Linear(None, n_units),
...             L.Linear(n_units, n_units),
...             L.Linear(n_units, n_out),
...         )
```

June 1-2, 2018

Deep Learning and physics 2018



Target scope of Workshop

Deep learning plays a central role in recent developments in research in artificial intelligence (AI). Various ideas based on physics are found in the research of deep learning, and consequently, deep learning and physics are related intimately. This workshop is dedicated to (1) applications of deep learning to physics, (2) discovering similarities among deep learning and physics, and (3) leading to new paradigm in physics motivated by deep learning. Researchers in related fields are welcome to attending discussions at our workshop.

深層学習(deep learning)は人工知能(Artificial Intelligence, AI)研究の中心的存在であり、近年大きな発展を遂げています。その中には物理学に基礎を置く考え方が多く見られ、結果として必然的に、深層学習と物理学は大変親密な関係にあります。本研究会は、深層学習の物理学研究への応用、また、理論的枠組みの相似性を探求し理論物理学において新たな技法とパラダイムを開拓すべく、企画されました。急速に進展する本研究分野の議論に、多数の研究者のご参加を期待します。



string data

a 2017 workshop on data science and string theory

nov 30th - dec 2nd

organized by Jim Halverson, Cody Long and Brent Nelson

speakers:

- Frederik Denef *Columbia University*
- Keith Dienes *University of Arizona*
- Michael Douglas *Simons Center for Geometry and Physics*
- Yang-Hui He *City University of London*
- Dima Krioukov *Northeastern University*
- Sven Krippendorf *Oxford University*
- Cody Long *Northeastern University*
- Fernando Marchesano *IFT-Madrid*
- Bryan Ostdiek *University of Oregon*
- Fernando Quevedo *ICTP and Cambridge University*
- Fabian Ruehle *Oxford University*
- Rak-Kyeong Seong *Tsinghua University*
- Gary Shiu *University of Wisconsin*
- Cumrun Vafa *Harvard University*
- Washington Taylor *MIT*
- Yi-Nan Wang *MIT*



string_data: workshop on data science and string theory

26-29 March 2018

ASC

Europe/Berlin timezone

Overview

Scientific Programme

Timetable

Contribution List

Author List

workshop (March 26-28) - hackathon (March 29)

The goal is to bring together string theorists and data scientists to discuss how big data techniques can be utilised to understand the "string landscape". This meeting will feature talks, specialised discussion groups, and the first string theory hackathon.

One objective of this workshop is to present the status of data science methods applied to string theory and to survey our current understanding of the landscape. Another objective is to provide an opportunity for string theorists and data scientists to identify optimal future targets.

Organizers:

Thomas Grimm

Sven Krippendorf

Dieter Lüst

ARNOLD SOMMERFELD
CENTER FOR THEORETICAL PHYSICS



Previous workshop 2017: Northeastern, Boston ([link](#))

Machine Learning and Physics

2018-07-04--2018-07-06

北京



[Home](#) [Registration](#) [Links](#)

- [Announcement](#)
- [Organizing Committee](#)
- [Invited Speakers](#)
- [Conference Program](#)
- [Hotel Information](#)
- [Conference Venue](#)
- [Contact Us](#)

There is an increasing interest in bringing together the machine learning and physics research, and a large number of interesting works have been done in the recent few years. On one hand, the newly developed of machine learning algorithms can find more applications in physics research, and on the other hand, physics ideas can also inspire new development in machine learning.

Under this background, we organize a series of biannual international workshop on “ Machine Learning and Physics ”, and this is the first one. This workshop aims at bringing together leading experts in the field and discussing the current developments and future perspectives of this field. We hope that this series of conference can create a large impact in this fast developing field and stimulate more collaboration between Chinese and international communities.

This conference plans to focus on the connection between machine learning and various branches of physics, including


- Quantum Many-body/Condensed Matter Physics
- Quantum Information and Quantum Computer
- Statistical Mechanics
- Computational Physics
- High-energy Physics
- Astrophysics

The topics include (but not limited to)

MACHINE LEARNING LANDSCAPE

String Theory, Machine Learning, and Energy Landscapes

10 December - 12 December 2018
ICTP Trieste



Organization:

- Sven Krippendorf (LMU Munich)
- Fabian Ruehle (CERN)
- Dhaghash Mehta (United Technologies)
- Fernando Quevedo (ICTP)

Homepage and registration:

- <http://indico.ictp.it/event/8784/overview>

Tsinghua Workshop on Machine Learning in Geometry and Physics 2018

10-15 June 2018

Tsinghua Sanya International Mathematics Forum

Asia/Shanghai timezone



Overview

Timetable

Contribution List

Participant List



We are pleased to announce the first workshop on machine learning in geometry and physics at the Tsinghua Sanya International Mathematics Forum, 11-15 June 2018.

The goal of the workshop is to explore how machine learning techniques can be applied in modern mathematics and theoretical physics. We intend to bring together a diverse set of experts whose research interests and expertise are of general interest for researchers who are trying to approach research problems in formal physics and mathematics from a data science perspective. Some of the topics the workshop intends to cover:

- String landscape from a data science perspective
- Holography, RG flows and deep learning
- Novel geometric relations from data mining



Physics n ML

Overview

Region: North America


Date: April 25, 2019 - April 26, 2019

Location: Redmond, Washington, USA

Venue: Microsoft Research Building 99/1919

[About](#) [Agenda](#)

The goal of *Physics n ML* (read 'Physics Meets ML') is to bring together researchers from machine learning and physics to learn from each other and push research forward together. In this inaugural edition, we will especially highlight some amazing progress made in string theory with machine learning and in the understanding of deep learning from a physical angle. Nevertheless, we invite a cast with wide ranging expertise in order to spark new ideas. Plenary sessions from experts in each field and shorter specialized talks will introduce existing research. We will hold moderated discussions and breakout groups in which participants can identify problems and hopefully begin new collaborations in both directions. For example, physical insights can motivate advanced algorithms in machine learning, and analysis of geometric and topological datasets with machine learning can yield critical new



1st Workshop on Scientific-Driven Deep Learning (SciDL)

8:00-14:30 (PST) on Wednesday July 1, 2020

Location: Zoom

Register here:

<https://forms.gle/o1WCSBTbeoahj5ww8>

Deep learning is playing a growing role in the area of fluid dynamics, climate science and in many other scientific disciplines. Classically, deep learning has focused on an model agnostic learning approaches ignoring any prior knowledge that is known about the

物理学から見る深層学習

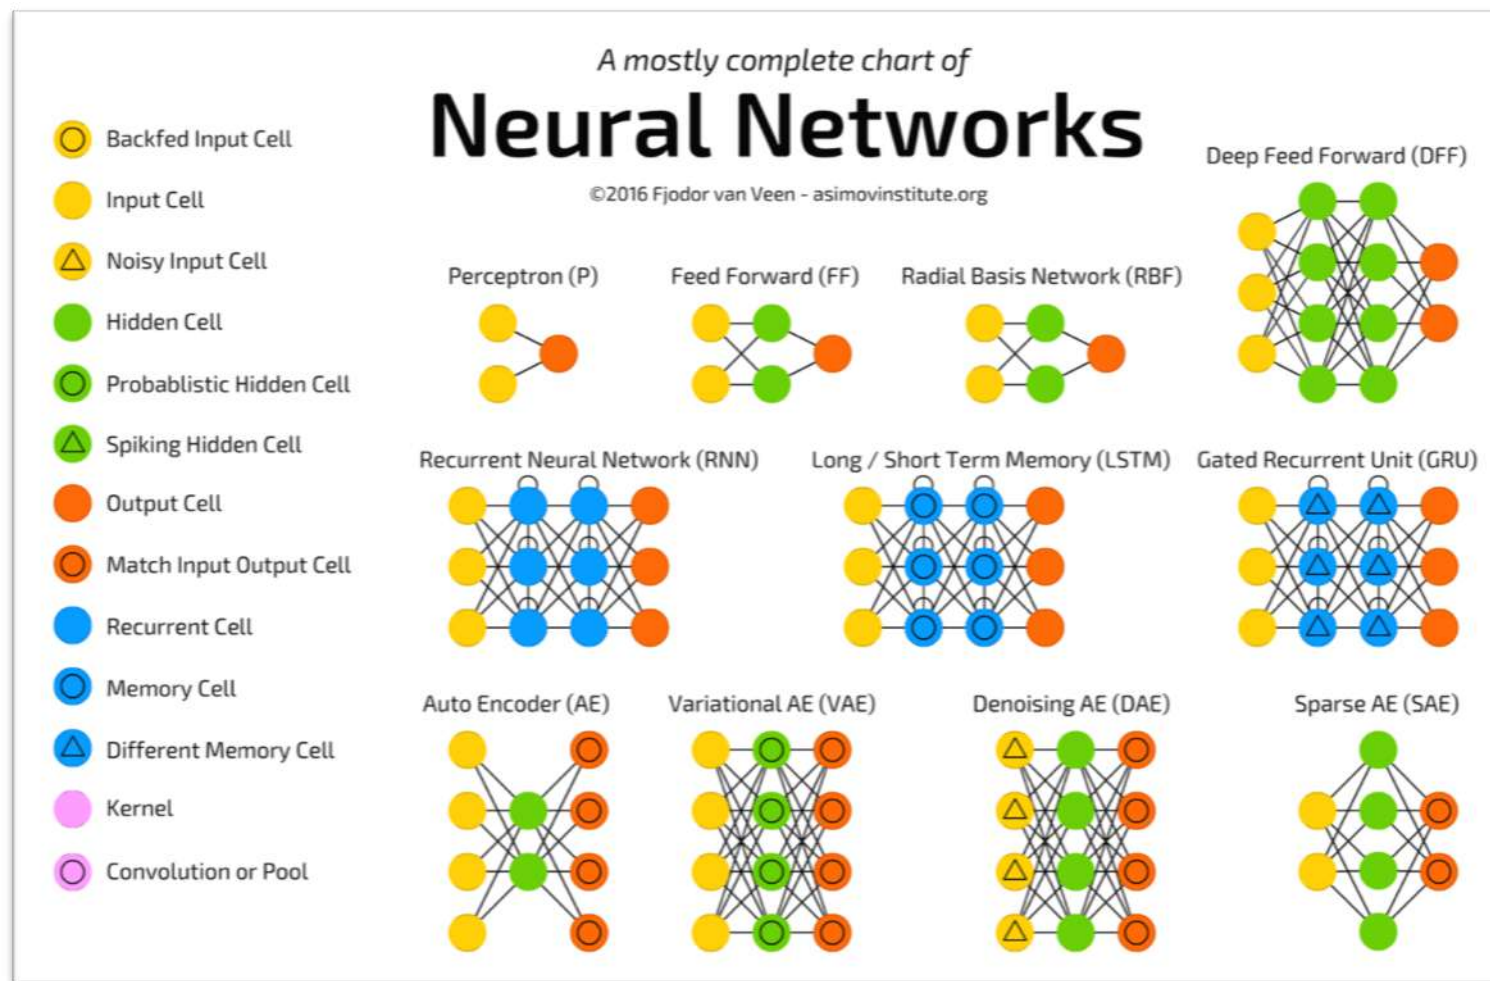
1. ニューラルネットワーク
2. 深層学習
3. 逆問題と物理学の革新

深層学習による物理学


4. 物性物理学と深層学習
5. 量子重力理論
6. AdS/CFT対応と深層学習

1. ニューラルネットワーク


多くの種類が発明されてきた



Markov Chain (MC)



Hopfield Network (HN)




Boltzmann Machine (BM)




Restricted BM (RBM)




Deep Belief Network (DBN)




Deep Convolutional Network (DCN)




Deconvolutional Network (DN)




Deep Convolutional Inverse Graphics Network (DCIGN)




Generative Adversarial Network (GAN)




Liquid State Machine (LSM)




Extreme Learning Machine (ELM)



Echo State Network (ESN)




Deep Residual Network (DRN)




Kohonen Network (KN)



Support Vector Machine (SVM)



Neural Turing Machine (NTM)




1. ニューラルネットワーク

機械学習 = 関数近似

入力: (v_1, v_2, v_3, \dots) \xrightarrow{f} 出力: $f(v_1, v_2, v_3, \dots)$


ニューラルネットワーク = 関数のアンザッツ



パーセプトロン 模型

[Rosenblatt 1958]

[Rumelhart, McClelland 1986]



ボルツマンマシン


[Ackley, Hinton, Sejnowski 1985]

- 万能近似定理:

多層・多ユニットのニューラルネットワークはあらゆる関数を近似できる [Cybenko 1989] [Roux, Bengio 2008]

1. ニューラルネットワーク

パーセプトロンは分類を学習



$$f = W_i^{(2)} \varphi \left(W_{ij}^{(1)} x_j \right)$$

“ユニット” (丸印) : ベクトル成分値

“重み” (線) : 線形変換、のちに最適化

“活性化関数” (線の端) :
非線形な成分ごとの作用、固定

$$\varphi(x) \equiv \frac{1}{1 + e^{-x}}$$


学習の方法

- 1) {入力値, 出力値} セット (学習データ) を大量に用意
- 2) W を変更していくことで、

誤差関数 $E \equiv \sum_{\text{data}} \left| f - W_i^{(2)} \varphi \left(W_{ij}^{(1)} x_j \right) \right|$ を小さくする

1. ニューラルネットワーク

ボルツマンマシンは確率分布を学習



“ユニット” (丸印) : スピン値
“可視ユニット” (黄色) : 入力
“隠れユニット” (緑色) : 積分
“重み” (線) : スピンスピン結合
(のちに最適化)

$$P(v_i) = \sum_{h_i \in \{0,1\}} \exp[-\mathcal{E}(v_i, h_i)]$$

$$\mathcal{E}(v_i, h_i) \equiv \sum_{ij} w_{ij} v_i h_j$$

学習の方法

- 1) 入力+出力 $\{(v_i, P_{\text{ex}}(v_i))\}$ のセットを大量に用意
- 2) W を変更していくことで、誤差関数
 $E \equiv D_{\text{KL}}(P_{\text{ex}}(v_i) || P(v_i))$ を小さくする

物理学から見る深層学習

1. ニューラルネットワーク
2. 深層学習
3. 逆問題と物理学の革新

深層学習による物理学

4. 物性物理学と深層学習
5. 量子重力理論
6. AdS/CFT対応と深層学習

2. 深層学習

深層ニューラルネットワーク

パーセプトロンを何層にも重ねる

$$y_{i_n} = f_n(a_{i_n i_{n-1}}^{(n)} x_{i_{n-1}}^{(n-1)} + b_{i_n}^{(n)})$$

$$x_{i_{n-1}}^{(n-1)} = f_{n-1}(a_{i_{n-1} i_{n-2}}^{(n-1)} x_{i_{n-2}}^{(n-2)} + b_{i_{n-1}}^{(n-1)})$$


⋮

$$x_{i_1}^{(1)} = f_1(a_{i_1 i_0}^1 x_{i_0} + b_{i_1}^1)$$

パラメータ： $\left\{ \begin{array}{l} \text{定数} \left\{ \begin{array}{l} a^{(1)}, a^{(k)}, \dots, a^{(n)} \\ b^{(1)}, b^{(k)}, \dots, b^{(n)} \end{array} \right. \text{「重み」} \\ \text{関数} \quad f_1(x), f_2(x), \dots, f_n(x) \text{「活性化関数」} \end{array} \right.$

2. 深層学習

深層学習 = 多層ニューラルネットワークでの学習



2. 深層学習


活性化関数は非線形性を与える

目的に応じて選ぶ { 学習の効率化
NNの性質... など

1) sigmoid関数

$$f(x) = \frac{1}{e^{-x} + 1}$$

ニューロンの発火を
まねて考えられた値



{ $x < 0$ で発火しない
 $x > 0$ で発火


$x = 0$ が発火のしきい値

2. 深層学習

多用される標準的な活性化関数

2) ReLu (Rectified Linear unit)

$$f(x) = \begin{cases} x & (x \geq 0) \\ 0 & (x < 0) \end{cases}$$



多層化による勾配消失の問題を回避できる

($\frac{\partial E}{\partial a^{(1)}} = f'_n f'_{n-1} f'_{n-2} \dots$ とかけあわされる問題)

物理学から見る深層学習

1. ニューラルネットワーク
2. 深層学習
3. 逆問題と物理学の革新

深層学習による物理学

4. 物性物理学と深層学習
5. 量子重力理論
6. AdS/CFT対応と深層学習

3. 逆問題と物理学の革新

物理学の「問題」には種類がある

関数 $y = f(x)$ についての問題とは？

	f	x	y
順問題	知	知	未知
逆問題(1) 初期値問題	知	未知	知
逆問題(2) システム決定問題	未知	知	知

逆問題の
一般的性質

- ・ 直接測れない
- ・ 結果から原因を知る
- ・ 物理定数を決定する
- ・ 物理法則の同定

逆問題(1)


逆問題(2)

3. 逆問題と物理学の革新

深層学習はシステム決定問題を解く

逆問題 (2) システム決定問題とは:

データ $\{(x_1, y_1), (x_2, y_2), \dots\}$ を元に、
関数 $f(x)$ を決定する問題



深層学習は「f」を求める

3. 逆問題と物理学の革新

逆問題を解くことは物理学の革新を導く



ティコ・ブラーエ (1546-1601)

詳細な惑星観測を行なった

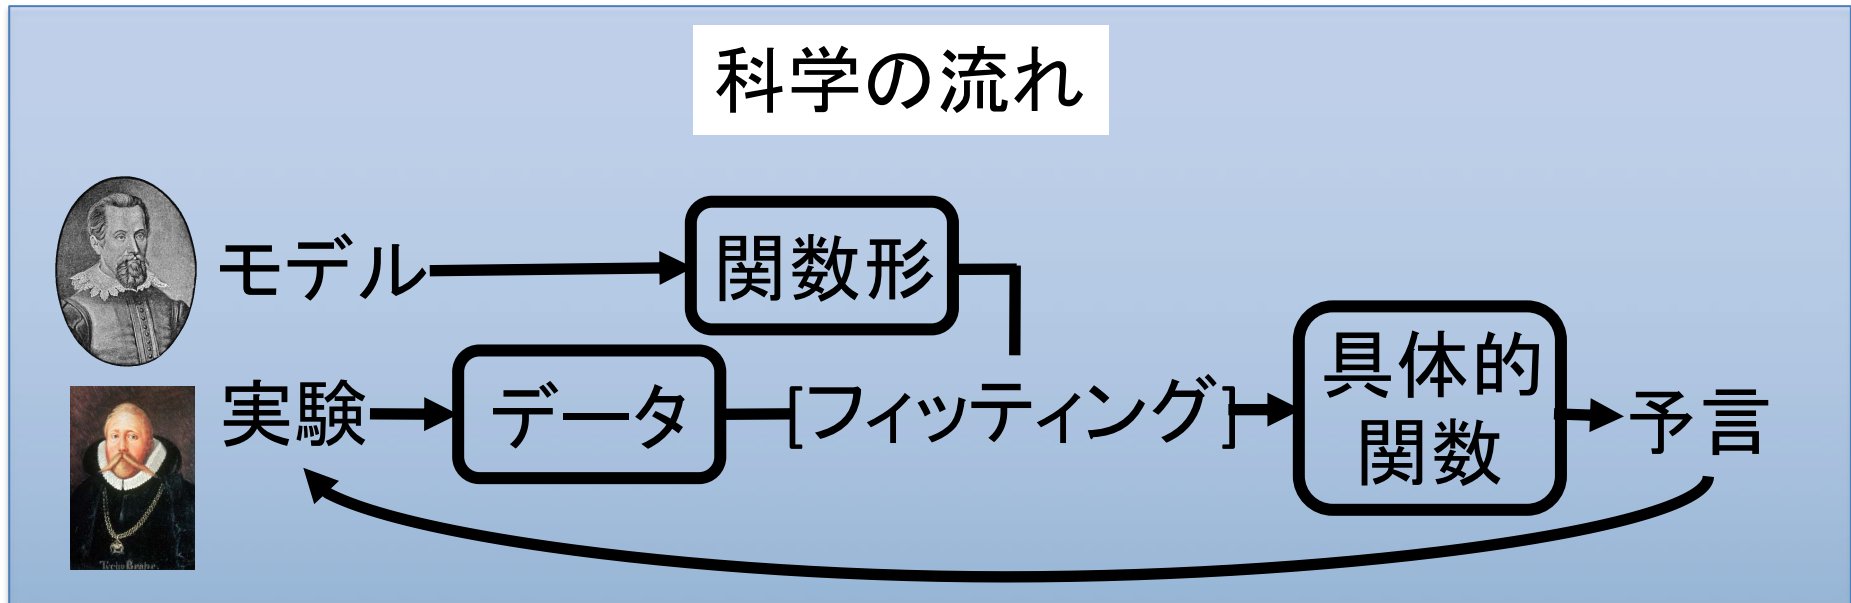


ヨハネス・ケプラー (1571-1630)

ティコ・ブラーエの観測データから
「ケプラーの第一法則」を発見
(惑星の運動は太陽を焦点とした
楕円軌道である)

3. 逆問題と物理学の革新

科学の流れと機械学習



機械学習の位置づけ？

教師付き学習： 関数形の制限がないフィッティング

教師なし学習： データの自動分類

強化学習： 解けなかったモデルを解くトライアル

物理学から見る深層学習

1. ニューラルネットワーク
2. 深層学習
3. 逆問題と物理学の革新

深層学習による物理学

4. 物性物理学と深層学習
5. 量子重力理論
6. AdS/CFT対応と深層学習



観測成果

ツイート


この記事を印刷する

遠方にある超新星の大量発見で宇宙膨張の謎に迫る 2019年5月29日 (ハワイ現地時間)

HSC16aasd (nonla, $z=0.19$)



HSC17bigx (la, $z=1.00$)



HSC17bqai (la, $z=0.38$)




HSC16aqfi (la, $z=1.25$)



HSC17bjyn (la, $z=0.63$)




HSC17aydg (la, $z=1.45$)



HSC17cbcd (la, $z=0.87$)



HSC16adga (SLSN, $z=2.40$)




Machine Learning and Quantum Computing for High-Energy Physics

Introduction



Importance of Machine Learning in international experiments are increasing. Deep Learning (DL) is becoming a driver at the center.

Development for practical use of quantum machines for the gate-type QCs in experiments.



performance. The big
the recent development of Deep
physics have being pursued in our

le in a market, and $O(10)$ qubit
es in high-energy physics



田中章詞さん
(理研iTHEMS)



富谷昭夫さん
(理研BNL)

「機械学習と物理」のトピック

量子多体系の基底状態の波動関数

[Carleo Troyer Science355 (2017)602]

NNの時空解釈と物理系への応用

[Tanaka Tomiya Sugishita KH Phys.Rev.D98(2018)046019]

自己学習モンテカルロ、有効理論構築

[Liu Qi Meng Fu Phys.Rev.B95(2017)]

分子動力学法

[Behler J.Chem.Phys.145(2016)170901]

相図の予想、相転移の検出 [Ohtsuki Ohtsuki JPSJ85 (2016)123706]

[Tanaka Tomiya JPSJ86(2017)963001]

物理量の関係間の写像

[Fujimoto Fukushima Murase Phys. Rev.D98(2018)]

解の探索と分類

[He Phys.Lett.B774(2017)564]

[Carifio Halverson Krioukov Nelson JHEP09(2017)157]

4. 物性物理学と深層学習

基底状態のためのアンザッツ


N個のスピンの波動関数: $\psi(s_1, s_2, \dots, s_N)$

与えられたハミルトニアンでエネルギーを最小に？

$$E = \sum_{\{s_1, s_2, \dots, s_N\}} \psi^\dagger(s_1, s_2, \dots, s_N) \hat{H} \psi(s_1, s_2, \dots, s_N)$$


- 行列積状態

$$\psi(s_1, s_2, \dots) = \text{tr}[A^{(s_1)} A^{(s_2)} \dots]$$



- テンソルネット状態

$$\psi(s_1, s_2, \dots) = \sum_{m,n} B_{mn} A_{ms_1s_2} A_{ns_3s_4}$$



4. 物性物理学と深層学習


ニューラルネットワーク状態

- ボルツマンマシン状態

[Carleo Troyer `17],

[Nomura, Darmawan, Yamaji, Imada `17], ..


$$\psi(s_1, \dots, s_N) = \sum_{h_A} \exp \left[\sum_a a_a s_a + \sum_A b_A h_A + \sum_{a,A} J_{aA} s_a h_A \right]$$



- 深層ボルツマンマシン状態

[Carleo, Nomura, Imada `18], ..


$$|\psi\rangle = \lim_{\tau \rightarrow \infty} e^{-\tau H} |\text{any}\rangle = e^{-\Delta\tau H} e^{-\Delta\tau H} \dots |\text{any}\rangle$$



- フィードフォワードニューラルネットワーク状態

[Saito `18], ..

$$\psi(s_1, \dots, s_N) = \sum_i f_i \sigma \left(\sum_j W_{ij} s_j + b_i \right)$$



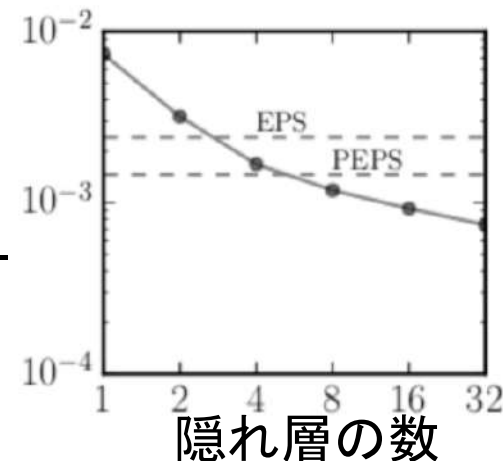
4. 物性物理学と深層学習

深層学習が勝る場合がある

例: 2次元反強磁性
ハイゼンベルグ模型

[Carleo, Troyer `17]

ボルツマン
マシン状態
のエネルギー



様々な状態の関係

1) ボルツマンはテンソルネット

[Chen, Cheng, Xie, Wang, Xiang `18]

2) テンソルネットは深層ボルツマン

[Gao, Duan `17] [Huang, Moore `17]

3) テンソルネットは「積プーリング」のフィードフォワード

[Cohen, Shashua `18]

物理学から見る深層学習

1. ニューラルネットワーク
2. 深層学習
3. 逆問題と物理学の革新

深層学習による物理学

4. 物性物理学と深層学習
5. 量子重力理論
6. AdS/CFT対応と深層学習

5. 量子重力理論

ミクロの時空はネットワークである


20世紀物理学の最後の宿題： 量子重力理論

レグジュ計算

[Regge 1961]


力学的単体分割

[Ambjorn, Loll 1998]




テンソル
ネットワーク

[Swingle `09]



ホログラフィー
原理の量子コード

[Pastawski, Yoshida,
Harlow, Preskill `15]



5. 量子重力理論

量子重力の歴史

1970年 南部、Susskind、Nielsen、ハドロンの弦理論。

1974年 米谷、ScherkとSchwarz が、弦理論が重力を含むことを発見。重力の量子論へ。

Yoneya, Prog.Theor.Phys. 51 (1974) 1907.

Scherk, Schwarz, Nucl.Phys. B81 (1974) 118.

1976年 Hawking、ブラックホールの情報喪失問題。

Hawking, Phys.Rev.D14(1976)2460.

1988年 ループ量子重力。

Rovelli, Smolin.

1997年 Maldacena が AdS/CFT 対応を発見。
(ホログラフィー原理の具体例。)

ある量子重力理論が定義される

Maldacena, Adv.Theor.Math.Phys. 2 (1998) 231.

5. 量子重力理論

量子重力の歴史

- 2002年 ホログラフィックQCD。 Karch, Katz, JHEP 0206:043.
Kruczenski, Mateos, Myers, Winters JHEP 0405:041.
Sakai, Sugimoto, PTP 113 (2004) 843.
- 2006年 笠、高柳、エンタングルメント公式の発見。
Ryu, Takayanagi, JHEP 0608:045.
- 2008年 ホログラフィック超伝導。
Hartnoll, Herzog, Horowitz, PRL 101(2008)031601.
- 2009年 量子重力を創発する条件。
Heemskerk, Penedones, Polchinski, Sully, JHEP 0910:079.
- 2014年 KitaevがSYK模型(重力双対量子力学)を発見。
- 2017年 アインシュタイン方程式(非線形)の導出。
Faulkner, Haehl, Hijano, Parrikar, Rabideau, Van Raamsdonk, JHEP 1708:057.

5. 量子重力理論

未だ証明の無い AdS/CFT対応

[Maldacena, Adv.Theor.Math.Phys. 2 (1998) 231]

“CFT” (量子力学側)

d次元時空上の
場の量子論

ラージN極限 + 強結合

=

“AdS” (重力側)

(d+1)次元時空上の
~~量子重力~~

古典アインシュタイン重力

- 未証明 (物理的にも、いわんや数学的にも)
- 左が与えられた時にどうやって右を得るか?
- 物理量の一致が多例で知られている
- Maldacenaの論文は高エネルギー物理業界で最も引用

5. 量子重力理論

辞書: 分配関数の一致

[Gubser, Klebanov, Polyakov, Phys.Lett.B428(1998)105]

[Witten, Adv.Theor.Math.Phys. 2 (1998) 253]

量子力学の
分配関数

=

重力理論の
分配関数



$$\int [\mathcal{D}q(t)] e^{-\int dt \mathcal{L}[q, \dot{q}]}$$

$$\int [\mathcal{D}g_{\mu\nu}(t, z)] e^{-\int dt dz (\sqrt{-\det g} R[g] + \dots)}$$

⇩ ソース $J(t)$ を導入

⇩ 古典化

$$\int [\mathcal{D}q(t)] e^{-\int dt \mathcal{L}[q, \dot{q}] - \int dt J(t) \mathcal{O}[q]} = e^{-\int dt dz (\sqrt{-\det g} R[g] + \dots)}$$



物理学から見る深層学習

1. ニューラルネットワーク
2. 深層学習
3. 逆問題と物理学の革新


深層学習による物理学

4. 物性物理学と深層学習
5. 量子重力理論
6. AdS/CFT対応と深層学習

6. AdS/CFT対応と深層学習


時空をニューラルネットワークと見る

深層
学習



ホログラフィー
原理

[Maldacena '97]





物理系

創発時空

ブラック
ホール

6. AdS/CFT対応と深層学習

時空をニューラルネットワークと見る



ホログラフィー	深層学習
創発空間方向	層の深さ
重力場	ネットワークの重み
量子系の実験データ	入力データ
ブラックホール条件	出力データ
重力相互作用	活性化関数

6. AdS/CFT対応と深層学習

最も簡単化した重力側の理論を用意

未知の5次元時空上のスカラー場理論

$$S = \int d\eta d^4x \sqrt{\det g} [(\partial_\eta \phi)^2 - V(\phi)]$$

1802.08313

1809.10536

$$ds^2 = -f(\eta)dt^2 + d\eta^2 + g(\eta)(dx_1^2 + \cdots + dx_{d-1}^2)$$

$$\left\{ \begin{array}{l} \text{境界} (\eta \sim \infty) \text{でAdS: } f \sim g \sim \exp[2\eta/L] \\ \text{ブラックホール} (\eta \sim 0): f \sim \eta^2, g \sim \text{const.} \end{array} \right.$$

辞書: 運動方程式の解は量子力学の応答 $\langle \bar{\psi} \psi \rangle_{m_q}$


[Klebanov, Witten '98]

$$\left\{ \begin{array}{l} \text{境界} (\eta \sim \infty): \phi = m_q e^{-\eta} + \langle \bar{\psi} \psi \rangle e^{-3\eta} \\ \text{ホライズン} (\eta \sim 0) \text{では: } \partial_\eta \phi \big|_{\eta=0} = 0 \end{array} \right.$$

6. AdS/CFT対応と深層学習


運動方程式をNNで表す

運動方程式 $\partial_\eta^2 \phi + \underbrace{h(\eta)}_{\text{メトリック}} \partial_\eta \phi - \frac{\delta V[\phi]}{\delta \phi} = 0$




メトリック $h(\eta) \equiv \partial_\eta \left[\log \sqrt{f(\eta)g(\eta)^{d-1}} \right]$

空間を離散化
ハミルトン形式 $\begin{cases} \phi(\eta + \Delta\eta) = \phi(\eta) + \Delta\eta \pi(\eta) \\ \pi(\eta + \Delta\eta) = \pi(\eta) + \Delta\eta \left(h(\eta)\pi(\eta) - \frac{\delta V(\phi(\eta))}{\delta \phi(\eta)} \right) \end{cases}$




Feedforward NN 表現



6. AdS/CFT対応と深層学習

量子力学(QCD)のデータでNNを学習させる




学習された (AdS 半径)⁻¹: $1/L = 237(3)$ [MeV]

スカラー場の自己結合: $\lambda/L = 0.0127(6)$

6. AdS/CFT対応と深層学習

学習で創発した時空から、予言してみる


学習で創発した時空



丘

Cf) 人間が慮った時空

$$ds^2 = \frac{e^{cz/2}}{z^2} \left((1 - z^4)dt^2 + dx_i^2 + \frac{1}{1 - z^4} dz^2 \right)$$



[Andreev, Zakharov, '06, '07]

アインシュタイン方程式

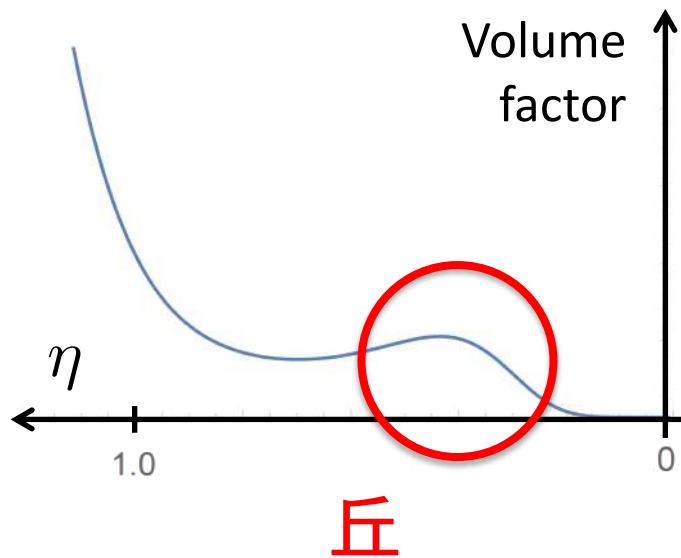
の解では無い。量子重力効果？

Cf [Hyakutake '14]


6. AdS/CFT対応と深層学習

学習で創発した時空から、予言してみる


学習で創発した時空



クォーク間ポテンシャル



[Petreczky, '10]



物理学から見る深層学習


1. ニューラルネットワーク
2. 深層学習
3. 逆問題と物理学の革新

深層学習による物理学

4. 物性物理学と深層学習
5. 量子重力理論
6. AdS/CFT対応と深層学習

A-1

物理学における機械学習は「第3の実験」



第1の実験

実世界での実験

第2の実験

数値実験（仮想世界での実験）

第3の実験

機械学習