

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

Interpretable Conservation Law Estimation by Deriving the Symmetries of Dynamics  
from Trained Deep Neural Networks

<https://arxiv.org/abs/2001.00111>

統計数理研究所 統計的機械学習研究センター

特任助教 本武 陽一

# 自己紹介

福岡県福岡市出身

学歴：

2008/3 東北大学 理学部 物理学科卒業

2010/3 北海道大学 大学院理学院 宇宙理学専攻

修士課程修了 指導教官：石川健三 教授（素粒子物理学、テーマ：波束のダイナミクス）

2013/3 東京大学 大学院総合文化研究科 広域科学専攻

修士課程修了 指導教官：植田一博 教授（認知科学、テーマ：脳活動を用いたHAI評価）

2016/3 東京大学 大学院総合文化研究科 広域科学専攻

博士課程修了 指導教官：池上高志 教授（複雑系、テーマ：深層学習、群れ）

職歴：

2016/5 ～ 2019/3 東京大学 大学院新領域創成科学研究科 複雑理工学専攻


特任研究員（岡田真人教授、テーマ：データ駆動科学）

2019/4 ～ 統計数理研究所 統計的機械学習研究センター

特任助教（福水健次教授、テーマ：統計的機械学習）



# 自己紹介



群れ現象画像: [http://research.kyoto-u.ac.jp/service/topic/spirits/lists/h25list\\_j/sprits\\_h25ja\\_11\\_sakagami/](http://research.kyoto-u.ac.jp/service/topic/spirits/lists/h25list_j/sprits_h25ja_11_sakagami/)


磁区構造画像: [Y. Mototake, M. Mizumaki, K. Kudo, and K. Fukumizu in prep.] より

高分子構造画像: [M. Ito, S. Yamanaka, T. Aoyagi, and K. Ohnishi 2019] より

交通流画像: <https://www.sankei.com/photo/story/expand/180506/sty1805060010-p1.html>



# 集団運動の縮約モデル

● 集団運動が完全に他の運動と分離されている場合に有効な枠組み [澤田 80]



# 機械学習による物理モデル探索

## ●基底関数の結合によってハミルトニアンを構築




→基底関数が未知の場合には対応が難しい

[Michael Schmidt<sup>1</sup>, and Hod Lipson, Science 2009]

# 機械学習による物理モデル探索



## ● 深層学習によってハミルトニアンを構築



$$\mathcal{L}_{HNN} = \left\| \frac{\partial \mathcal{H}_\theta}{\partial \mathbf{p}} - \frac{\partial \mathbf{q}}{\partial t} \right\|_2 + \left\| \frac{\partial \mathcal{H}_\theta}{\partial \mathbf{q}} + \frac{\partial \mathbf{p}}{\partial t} \right\|_2$$

[G. Samuel, M. Dzamba, and J. Yosinski, NeurIPS 2019]

# 機械学習による物理モデル探索




➡ ハミルトニアンはブラックボックス

[G. Samuel, M. Dzamba, and J. Yosinski, NeurIPS 2019]

# 機械学習による物理モデル探索

非周期的秩序構造を持つ集団運動



群れ現象 磁区構造 高分子構造 交通流

科学者の洞察  
+ ベイズ推論  
による縮約

縮約モデル構築  
プロセス

科学者の洞察  
+ データ多様体の  
対称性評価

縮約モデル

大自由度群れ行動縮約モデル  
ドメインパターン形成モデル


縮約座標系

古典的座標系: フーリエ基底 etc  
トポロジカルな特徴量空間

ブラックボックスのハミルトニアン推定

# 抽象化と外挿による飛躍

[Guillemin, Amédée, "La vapeur", 1876]



蒸気機関

気体の現象論

$$PV = nRT$$

抽象的モデル化

$$dS = \frac{dQ}{T}$$

抽象モデルの外挿

$$G = H - TS$$


化学熱力学

反応速度論 etc.

[田辺工業株式会社HP より]




化学産業



Willard Gibbs


物理学者の深い洞察に基づき、モデルや知見の抽象化と、その大胆な外挿によって多くの進歩が実現されてきた → 機械学習にこのような外挿が実現できるとは思えない！

# 研究の目的



目的：縮約座標系を探索する物理学者に，その座標系を評価できる情報を提示する

# 研究の目的



学習済みDNNからの系の対称性推定を試みる

# 提案手法の説明のながれ

## 前提情報

1. ネーターの定理と時系列データ多様体の関係を検討
2. DNNによるデータ多様体のモデル化について検討

## 手法

3. DNNから系の対称性を抽出する手法の説明
4. 抽出された対称性から保存則を推定する手法の説明

# 提案手法の説明のながれ

## 前提情報

1. ネーターの定理と時系列データ多様体の関係を検討
2. DNNによるデータ多様体のモデル化について検討

## 手法

3. DNNから系の対称性を抽出する手法の説明
4. 抽出された対称性から保存則を推定する手法の説明

# ネーターの定理

## ネーターの定理：

ハミルトン系の持つ連続対称性と保存則を結びつける定理 [Noether 1918].

ハミルトニアン  $H(\mathbf{q}, \mathbf{p})$  と正準運動方程式  $\frac{\partial H(\mathbf{q}, \mathbf{p})}{\partial q_i} = -\dot{p}_i$ ,  $\frac{\partial H(\mathbf{q}, \mathbf{p})}{\partial p_i} = \dot{q}_i$  が、無限小変換  $(q'_i, p'_i) = (q_i + \delta q_{ij}, p_i + \delta p_{ij})$  に対して不変であるとする、保存量  $G_j$  との間に以下の関係式が成立する。

$$(\delta q_{ij}, \delta p_{ij}) = \left( \frac{\partial G_j}{\partial p_i}, -\frac{\partial G_j}{\partial q_i} \right)$$

# ネーターの定理

## 保存則に対応する不変性

ハミルトニアンの不変性： $H'(q, p) \equiv H(q, p)$

$$H'(Q, P) := H(q(Q, P), p(Q, P))$$

正準運動方程式の不変性：

$$\begin{cases} Q_{T+\Delta T} = \frac{\partial H'(Q_T, P_T)}{\partial P_T} \Delta T + Q_T \\ P_{T+\Delta T} = -\frac{\partial H'(Q_T, P_T)}{\partial Q_T} \Delta T + P_T \end{cases}$$

## 系を不変にする座標変換と無限小変換

$$\mathbb{C}(\boldsymbol{\theta}) : (q, p) \longmapsto (Q, P) := (Q(q, p, \boldsymbol{\theta}), P(q, p, \boldsymbol{\theta}))$$


$$Q(q, p, \boldsymbol{\theta} = \vec{0}) = q, P(q, p, \boldsymbol{\theta} = \vec{0}) = p$$

$$(\delta q_{ij}, \delta p_{ij}) = \left( \varepsilon \frac{\partial Q_i(q, p, \boldsymbol{\theta})}{\partial \theta_j} \Big|_{\boldsymbol{\theta}=\vec{0}}, \varepsilon \frac{\partial P_i(q, p, \boldsymbol{\theta})}{\partial \theta_j} \Big|_{\boldsymbol{\theta}=\vec{0}} \right) \quad |\varepsilon| \ll 1$$


# 時系列データとネーターの定理

本研究における力学系時系列データの定義

$$D := \left\{ \mathbf{q}_{t_i}^i, \mathbf{p}_{t_i}^i, \mathbf{q}_{t_i+\Delta t}^i, \mathbf{p}_{t_i+\Delta t}^i \right\}_{i=1}^N$$



[Mototake et al. 2015]



# 時系列データとネーターの定理


## ハミルトン系の対称性

ハミルトニアンの不変性： $H'(q, p) \equiv H(q, p)$

$$H'(Q, P) := H(q(Q, P), p(Q, P))$$

正準運動方程式の不変性：
$$\begin{cases} Q_{T+\Delta T} = \frac{\partial H(Q_T, P_T)}{\partial P_T} \Delta T + Q_T \\ P_{T+\Delta T} = -\frac{\partial H(Q_T, P_T)}{\partial Q_T} \Delta T + P_T \end{cases}$$

$$D := \left\{ \mathbf{q}_{t_i}^i, \mathbf{p}_{t_i}^i, \mathbf{q}_{t_i+\Delta t}^i, \mathbf{p}_{t_i+\Delta t}^i \right\}_{i=1}^N$$



## 力学系時系列データ多様体の対称性

ハミルトニアンの不変性： $\forall E, \{q, p \mid H(q, p) = E\} = \{Q, P \mid H(q, p) = E\}$

$$\begin{aligned} \text{正準運動方程式の不変性: } & \left\{ \mathbf{q}_{t+\Delta t}, \mathbf{p}_{t+\Delta t}, \mathbf{q}_t, \mathbf{p}_t \mid \mathbf{p}_{t+\Delta t} = \mathbf{p}_t - \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{q}_t} \Delta t, \mathbf{q}_{t+\Delta t} = \mathbf{q}_t + \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{p}_t} \Delta t \right\} \\ & = \left\{ \mathbf{Q}_{T+\Delta T}, \mathbf{P}_{T+\Delta T}, \mathbf{Q}_T, \mathbf{P}_T \mid \mathbf{p}_{t+\Delta t} = \mathbf{p}_t - \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{q}_t} \Delta t, \mathbf{q}_{t+\Delta t} = \mathbf{q}_t + \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{p}_t} \Delta t \right\} \end{aligned}$$

# 時系列データとネーターの定理


## ハミルトン系の対称性

ハミルトニアンの不変性： $H'(q, p) \equiv H(q, p)$

$$H'(Q, P) := H(q(Q, P), p(Q, P))$$

正準運動方程式の不変性：
$$\begin{cases} Q_{T+\Delta T} = \frac{\partial H(Q_T, P_T)}{\partial P_T} \Delta T + Q_T \\ P_{T+\Delta T} = -\frac{\partial H(Q_T, P_T)}{\partial Q_T} \Delta T + P_T \end{cases}$$

$$D := \left\{ \mathbf{q}_{t_i}^i, \mathbf{p}_{t_i}^i, \mathbf{q}_{t_i+\Delta t}^i, \mathbf{p}_{t_i+\Delta t}^i \right\}_{i=1}^N$$




## 力学系時系列データ多様体の対称性

$$\begin{aligned} & \forall E, \left\{ \mathbf{q}_{t+\Delta t}, \mathbf{p}_{t+\Delta t}, \mathbf{q}_t, \mathbf{p}_t \mid H(\mathbf{q}_t, \mathbf{p}_t) = E, \mathbf{p}_{t+\Delta t} = \mathbf{p}_t - \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{q}_t} \Delta t, \mathbf{q}_{t+\Delta t} = \mathbf{q}_t + \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{p}_t} \Delta t \right\} \\ & = \left\{ \mathbf{Q}_{T+\Delta T}, \mathbf{P}_{T+\Delta T}, \mathbf{Q}_T, \mathbf{P}_T \mid H(\mathbf{q}_t, \mathbf{p}_t) = E, \mathbf{p}_{t+\Delta t} = \mathbf{p}_t - \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{q}_t} \Delta t, \mathbf{q}_{t+\Delta t} = \mathbf{q}_t + \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{p}_t} \Delta t \right\} \end{aligned}$$


# 時系列データとネーターの定理

問題の困難さの緩和：全エネルギーという条件の緩和

$$\forall E, \left\{ q_{t+\Delta t}, p_{t+\Delta t}, q_t, p_t \mid H(q_t, p_t) = E, p_{t+\Delta t} = p_t - \frac{\partial H(q_t, p_t)}{\partial q_t}, q_{t+\Delta t} = q_t + \frac{\partial H(q_t, p_t)}{\partial p_t} \right\}$$
$$= \left\{ Q_{T+\Delta T}, P_{T+\Delta T}, Q_T, P_T \mid H(q_t, p_t) = E, p_{t+\Delta t} = p_t - \frac{\partial H(q_t, p_t)}{\partial q_t}, q_{t+\Delta t} = q_t + \frac{\partial H(q_t, p_t)}{\partial p_t} \right\}$$



ハミルトニアンを不変にする変換,  $\forall E, \{q, p \mid H(q, p) = E\} = \{Q, P \mid H(q, p) = E\}$ は  
を変えない  $\rightarrow$  あるエネルギーに対応する時系列データ多様体の持つ対称性の中に、  
系の対称製の候補が必ず含まれる。




$$\left\{ q_{t+\Delta t}, p_{t+\Delta t}, q_t, p_t \mid H(q_t, p_t) = E_i, p_{t+\Delta t} = p_t - \frac{\partial H(q_t, p_t)}{\partial q_t}, q_{t+\Delta t} = q_t + \frac{\partial H(q_t, p_t)}{\partial p_t} \right\}$$
$$= \left\{ Q_{T+\Delta T}, P_{T+\Delta T}, Q_T, P_T \mid H(q_t, p_t) = E_i, p_{t+\Delta t} = p_t - \frac{\partial H(q_t, p_t)}{\partial q_t}, q_{t+\Delta t} = q_t + \frac{\partial H(q_t, p_t)}{\partial p_t} \right\}$$


# 時系列データとネーターの定理

問題の困難さの緩和：全エネルギーという条件の緩和

$$\forall E, \left\{ q_{t+\Delta t}, p_{t+\Delta t}, q_t, p_t \mid H(q_t, p_t) = E, p_{t+\Delta t} = p_t - \frac{\partial H(q_t, p_t)}{\partial q_t}, q_{t+\Delta t} = q_t + \frac{\partial H(q_t, p_t)}{\partial p_t} \right\}$$
$$= \left\{ Q_{T+\Delta T}, P_{T+\Delta T}, Q_T, P_T \mid H(q_t, p_t) = E, p_{t+\Delta t} = p_t - \frac{\partial H(q_t, p_t)}{\partial q_t}, q_{t+\Delta t} = q_t + \frac{\partial H(q_t, p_t)}{\partial p_t} \right\}$$



ハミルトニアンを不変にする変換,  $\forall E, \{q, p \mid H(q, p) = E\} = \{Q, P \mid H(q, p) = E\}$ は  
を変えない  $\rightarrow$  あるエネルギーに対応する時系列データ多様体の持つ対称性の中に、  
系の対称製の候補が必ず含まれる。



$$S_i := \left\{ q_{t+\Delta t}, p_{t+\Delta t}, q_t, p_t \mid H(q_t, p_t) = E_i, p_{t+\Delta t} = p_t - \frac{\partial H(q_t, p_t)}{\partial q_t}, q_{t+\Delta t} = q_t + \frac{\partial H(q_t, p_t)}{\partial p_t} \right\}$$


$\rightarrow$ ある特定エネルギー $E_i$ での時系列データ多様体 $S_i$ の対称性を調べるのが目標になった！！

# 深層ニューラルネットと多様体仮説

## 多様体仮説



the *manifold hypothesis* (Cayton, 2005; Narayanan and Mitter, 2010), according to which real-world data presented in high dimensional spaces are expected to concentrate in the vicinity of a manifold  $\mathcal{M}$  of much lower dimensionality  $d_{\mathcal{M}}$ , embedded in high dimensional input space  $\mathbb{R}^{d_x}$ . This can be a potentially

↓ Embedding result of hand write digit dataset(MNIST) using manifold learning (t-SNE)



# 深層ニューラルネットと多様体仮説

## 多様体仮説



[J.B. Tenenbaum 2000]  
Interpolations along straight lines  
in the Isomap coordinate space



# 深層ニューラルネットと多様体仮説

## ニューラルネットとデータ多様体


$$\mathbf{h} = (h_1, h_2, \dots, h_{d_h})$$

$$\varphi(\mathbf{w}^{\text{in}} \mathbf{x}) = (\varphi_1, \varphi_2, \dots, \varphi_{d_h}), \varphi_j = \varphi \left[ \sum_i^{d_{\text{in}}} (w_{ij}^{\text{in}} x_i) \right]$$

活性化関数:  $\varphi(x)$





ニューラルネットは、区分的な超平面の張り合わせで多様体をモデル化可能。





# 深層ニューラルネットと多様体仮説

## ニューラルネットとデータ多様体






接空間のtangent方向の右特異ベクトル  
[Bengio et.al, 2012] [Refai, & Bengio et al., 2011]



[入江・川人, 90]

- 0
- 1
- + 2
- + 3
- 4
- + 5
- + 6
- 7
- 8
- + 9



[Hinton et.al 06]


性能の高いDNNの中にデータ分布を多様体としてモデル化しているように見えるものが多い。

# ここまでのまとめ

- 時系列データ多様体 $S_i$ の座標変換に対する対称性をみることで、保存則がわかる。

$$S_i := \left\{ \mathbf{q}_{t+\Delta t}, \mathbf{p}_{t+\Delta t}, \mathbf{q}_t, \mathbf{p}_t \mid H(\mathbf{q}_t, \mathbf{p}_t) = E_i, \mathbf{p}_{t+\Delta t} = \mathbf{p}_t - \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{q}_t}, \mathbf{q}_{t+\Delta t} = \mathbf{q}_t + \frac{\partial H(\mathbf{q}_t, \mathbf{p}_t)}{\partial \mathbf{p}_t} \right\}$$

- DNNは多様体を超平面の貼り合わせのような形で表現できる。



[Basri et al. 16]

# 提案手法の説明のながれ


## 前提情報

1. ネーターの定理と時系列データ多様体の関係を検討
2. DNNによるデータ多様体のモデル化について検討

## 手法

3. DNNから系の対称性を抽出する手法の説明
4. 抽出された対称性から保存則を推定する手法の説明


# 手法1：対称変換の抽出



$$\left\{ X(\cdot) \mid \arg \min_X E_{\text{samp}}[X(\cdot)] \right\}$$


を満たす変換 $X(\cdot)$ の集合として対称変換の集合が得られる

# 手法1：対称変換の抽出



$$\left\{ \mathbf{Q}(\cdot, \cdot), \mathbf{P}(\cdot, \cdot) \mid \arg \min_{\mathbf{Q}(\cdot, \cdot), \mathbf{P}(\cdot, \cdot)} E_{\text{samp}} [\mathbf{Q}(\cdot, \cdot), \mathbf{P}(\cdot, \cdot)] \right\}$$

を満たす変換 $\mathbf{Q}(\cdot, \cdot), \mathbf{P}(\cdot, \cdot)$ の集合として対称変換の集合が得られる





サンプリング問題に置き換え

$$P(\mathbf{Q}(\cdot, \cdot), \mathbf{P}(\cdot, \cdot)) \sim \frac{1}{Z} \exp \left\{ -\frac{N}{2\sigma^2} E_{\text{samp}} [\mathbf{Q}(\cdot, \cdot), \mathbf{P}(\cdot, \cdot)] \right\}$$


# 手法1：対称変換の抽出

$$E_{\text{samp}}[X(\cdot)] = \frac{1}{N} \sum_{i=1}^N \{X(x_i) - f_{\text{DNN}}[X(x_i)]\}^2$$


← Compare →



Raw data



Forward →



Reconstructed data

$$P(Q(\cdot, \cdot), P(\cdot, \cdot)) \sim \frac{1}{Z} \exp \left\{ -\frac{N}{2\sigma^2} E_{\text{samp}} [Q(\cdot, \cdot), P(\cdot, \cdot)] \right\}$$

$$A(\theta) = \begin{pmatrix} a_{11}(\theta) & \dots & a_{1d}(\theta) \\ \vdots & \ddots & \vdots \\ a_{d1}(\theta) & \dots & a_{dd}(\theta) \end{pmatrix}$$

変換  $Q(\cdot, \cdot), P(\cdot, \cdot)$  を，線形変換

$$(Q, P)^t = A(q, p)^t$$

に限定して考える。

$$P(a_{11}, a_{12}, a_{21}, \dots, a_{2d} a_{2d}) = \frac{1}{Z} \exp \left[ -\frac{N}{2\sigma^2} E_{\text{samp}}(a_{11}, a_{12}, a_{21}, \dots, a_{2d} a_{2d}) \right]$$

# 手法1：対称変換の抽出


$$P(a_{11}, a_{12}, a_{21}, \dots, a_{2d 2d}) = \frac{1}{Z} \exp \left[ -\frac{N}{2\sigma^2} E_{\text{samp}}(a_{11}, a_{12}, a_{21}, \dots, a_{2d 2d}) \right]$$

- 交換モンテカルロ法 [Hukushima and Nemoto 1995]

$$P(A^l) = \frac{1}{Z} \exp \left[ -\beta \frac{N}{2\sigma^2} E_{\text{samp}}(A^l) \right]$$

以下の同時分布からMCMCサンプリング


$$P(A^1, A^2 \dots A^L) = \prod_{l=1}^L P(A^l)$$




# 手法1：対称変換の抽出

$$P(a_{11}, a_{12}, a_{21}, \dots, a_{2d 2d}) = \frac{1}{Z} \exp \left[ -\frac{N}{2\sigma^2} E_{\text{samp}}(a_{11}, a_{12}, a_{21}, \dots, a_{2d 2d}) \right]$$

- 交換モンテカルロ法 [Hukushima and Nemoto 1995]



(a)



# 手法1：対称変換の抽出

---

**Algorithm 1** Estimation of the invariant transformation set

---

**Input:** dataset  $D = \{\mathbf{q}_{t_i}^i, \mathbf{p}_{t_i}^i, \mathbf{q}_{t_i+\Delta t}^i, \mathbf{p}_{t_i+\Delta t}^i\}_{i=1}^N$  in a given coordinate system.

**Output:** Invariant transformation set  $D_a = \{(a_{11}, a_{12} \cdots, a_{1d}, a_{21} \cdots, a_{2d} \cdots, a_{2d} \cdots, a_{2d} \cdots)\}_{n_a=1}^{N_a}$ .

**Step 1:** Train the deep autoencoder with dataset  $D$ .



**Step 2:** Using the trained deep autoencoder and REMC method, sampling transformation parameters  $a_{11}, a_{12}, a_{21}, \cdots, a_{2d} \cdots$  from multiple probability distributions  $P'(a_{11}, a_{12}, a_{21}, \cdots, a_{2d} \cdots)$  corresponding to different noise intensities  $\sigma'$ .

**Step 3:** Select  $\sigma'$  from the distribution structure of the sampling results and output the sampling result of the selected  $\sigma'$  state as  $D_a$ .

---


# 手法2：無限小変換の推定

対称な変換の集合  $D_a := \{(a_{11}, a_{12}, \dots, a_{1d}, a_{21}, \dots, a_{2d}, \dots, a_{2d}, a_{2d})_{n_a}\}_{n_a=1}^{N_a}$



$$(\delta q_{ij}, \delta p_{ij}) = \left( \varepsilon \frac{\partial Q_i(q, p, \theta)}{\partial \theta_j} \Big|_{\theta=\vec{0}}, \varepsilon \frac{\partial P_i(q, p, \theta)}{\partial \theta_j} \Big|_{\theta=\vec{0}} \right)$$

無限小変換




$$M_{\text{invariant}} \sim \left\{ A(\theta) \begin{pmatrix} q \\ p \end{pmatrix} \mid \theta \in \mathbb{R}^{d_\theta} \right\}$$

リー群のなす多様体の接空間  $T_I M_{\text{invariant}}$

# 手法2：無限小変換の推定

## 対称変換の集合

$$D_a := \{(a_{11}, a_{12}, \dots, a_{1d}, a_{21}, \dots, a_{2d}, \dots, a_{d1}, \dots, a_{d2}, \dots, a_{dd})_{n_a}\}_{n_a=1}^{N_a}$$



$$A'(\boldsymbol{\theta}) = (a'_1(\boldsymbol{\theta}), \dots, a'_{d'}(\boldsymbol{\theta})) := (a_{11}(\boldsymbol{\theta}), \dots, a_{1d}(\boldsymbol{\theta}), a_{21}(\boldsymbol{\theta}), \dots, a_{2d}(\boldsymbol{\theta}), \dots, a_{d1}(\boldsymbol{\theta}), \dots, a_{d2}(\boldsymbol{\theta}), \dots, a_{dd}(\boldsymbol{\theta}))$$

$$\begin{cases} f_1(a'_1, \dots, a'_{d'}) = 0 \\ \vdots \\ f_{d'-d_\theta}(a'_1, \dots, a'_{d'}) = 0 \end{cases}$$

## リー群のなす多様体の陰関数表示




陰関数定理より

$$\text{ただし, } J_{kl} = \frac{\partial f_k(a'_1, \dots, a'_{d'})}{\partial b_l}$$

が正則であるとする.

$a_{ij}$  の一部を変換のパラメータ  $\theta$  とする  $\rightarrow$



$$(b_1, b_2, \dots, b_{d_\theta}) \subset A', \quad \{c_k\}_{k=1}^{d'-d_\theta} := A' \setminus \{b_l\}_{l=1}^{d_\theta}, \quad c_k = g_k(b_1, \dots, b_{d_\theta})$$

$$\begin{cases} h_1(c_1, b_1, \dots, b_{d_\theta}) = 0 \\ \vdots \\ h_{d'-d_\theta}(c_{d'-d_\theta}, b_1, \dots, b_{d_\theta}) = 0 \end{cases}$$

# 手法2：無限小変換の推定

$b$ を $\theta$ のかわりの連続パラメータと考えると、無限小変換を推定

$$\left\{ \begin{array}{l} \frac{\partial}{\partial b_l} h_1(c_1, b_1, \dots, b_{d_\theta}) \Big|_{A'=e_I} = 0 \\ \vdots \\ \frac{\partial}{\partial b_l} h_{d'-d_\theta}(c_{d'-d_\theta}, b_1, \dots, b_{d_\theta}) \Big|_{A'=e_I} = 0 \end{array} \right.$$

$$\begin{pmatrix} \delta q_l \\ \delta p_l \end{pmatrix} = \varepsilon \frac{A(b_l)}{\partial b_l} \Big|_{A=I} \begin{pmatrix} \mathbf{q} \\ \mathbf{p} \end{pmatrix} = \varepsilon \begin{pmatrix} \frac{\partial a_{11}}{\partial b_l} \Big|_{A=I} & \cdots & \frac{\partial a_{2d1}}{\partial b_l} \Big|_{A=I} \\ \vdots & \ddots & \vdots \\ \frac{\partial a_{12d}}{\partial b_l} \Big|_{A=I} & \cdots & \frac{\partial a_{2d2d}}{\partial b_l} \Big|_{A=I} \end{pmatrix} \begin{pmatrix} \mathbf{q} \\ \mathbf{p} \end{pmatrix}$$

# 手法2：無限小変換の推定

サンプリング結果  $D_b \equiv \{(c_k, b_1, b_2, \dots, b_{d'_\theta})_{n_a}\}_{n_a=1}^{N_a}$  を,

$$\hat{h}_k(c_k, b_1, b_2, \dots, b_{d'_\theta}; \beta, \gamma, d'_\theta) := \sum_{s_0=0}^{d_b} \sum_{s_1=0}^{d_b} \dots \sum_{s_{d'_\theta}=0}^{d_b} \gamma_{s_0 s_1 s_2 \dots s_{d'_\theta}} \beta_{s_0 s_1 s_2 \dots s_{d'_\theta}} c_k^{s_0} b_1^{s_1} b_2^{s_2} \dots b_{d'_\theta}^{s_{d'_\theta}} = 0$$

で直交距離回帰して、多様体の陰関数表示を得る.

$$\begin{cases} h_1(c_1, b_1, \dots, b_{d_\theta}) = 0 \\ \vdots \\ h_{d'-d_\theta}(c_{d'-d_\theta}, b_1, \dots, b_{d_\theta}) = 0 \end{cases}$$

ここで、 $\beta$  は回帰係数、 $\gamma$  は基底選択を表現するバイナリベクトルとする.

$\gamma$  は **ベイズ情報量基準 (BIC)** で決定する.

# 手法2：無限小変換の推定

---

## Algorithm 2 Estimation of infinitesimal transformation

---

**Input:** Sampling results of Method 1,  $D_a = \{(a_{11}, a_{12} \cdots, a_{1d}, a_{21} \cdots, a_{2d} \cdots, a_{2d} \cdots)\}_{n_a=1}^{N_a}$

**Output:** Infinitesimal transformation,  $\delta \mathbf{q}_l, \delta \mathbf{p}_l$ .

**Step 1:** Extract  $D_b = \{(c_k, b_1, b_2, \cdots, b_{d'_\theta})_{n_a}\}_{n_a=1}^{N_a}$  from  $D_a$ .

**Step 2:** Fit  $D_b$  with the implicit polynomial function  $\hat{h}_k(c_k, b_1^l, b_2^l, \cdots, b_{d'_\theta}^l; \beta, \gamma, d'_\theta)$  [Eq. (54)] for each  $c_k$ .

**Step 3:** Estimate the likelihood [Eq. (G1)] by numerical integration of  $Z$  [Eq. (G2)].

**Step 4:** Select the indicator vector  $\gamma$  and the dimension  $d'_\theta$  of  $M_{\text{invariant}}$  in Eq. (54) for each  $c_k$  using the BIC,

**Step 5:** Determine whether the Jacobi matrix  $J_{kl} = \frac{\partial h_k(c_k, b_1, \cdots, b_{d'_\theta})}{\partial b_l}$  is nonsingular. If  $J_{kl}$  is singular, return to Step 1 and re-extract  $D'_b$ .

**Step 6:** Differentiate the obtained simultaneous equations with respect to  $b_l$  around a point  $e_l$  to obtain Eq. (52).

**Step 7:** Solve the simultaneous equations in Eq. (52) and obtain the infinitesimal transformation,  $\delta \mathbf{q}_l, \delta \mathbf{p}_l$ .

---

# 提案手法のまとめ

## Definitions

$$H: M_E \rightarrow \mathbb{R}$$

$$H': M'_E \rightarrow \mathbb{R}$$

$$M_E := \{\mathbf{q}_t, \mathbf{p}_t \mid H(\mathbf{q}_t, \mathbf{p}_t) = E\}$$

$$M'_E := \{\mathbf{Q}_T, \mathbf{P}_T \mid H'(\mathbf{Q}_T, \mathbf{P}_T) = E\}$$

$$\mathbb{U}: (\mathbf{q}_t, \mathbf{p}_t) \mapsto (\mathbf{q}_{t+1}, \mathbf{p}_{t+1})$$

$$\mathbb{U}': (\mathbf{Q}_t, \mathbf{P}_t) \mapsto (\mathbf{Q}_{t+1}, \mathbf{P}_{t+1})$$


$$\mathbb{C}: (\mathbf{q}_t, \mathbf{p}_t, \mathbf{q}_{t+1}, \mathbf{p}_{t+1}) \mapsto (\mathbf{Q}_T, \mathbf{P}_T, \mathbf{Q}_{T+1}, \mathbf{P}_{T+1})$$

$$f_{\text{DNN}}(x) = \begin{cases} x & \text{if } x \in M_E \times \mathbb{U}(M_E) \\ y & \text{else} \end{cases}$$

where  $y \neq x$ .


$T_l M$ : tangent space of  $M$  at identity mat.

$G_l$ :  $\mathbb{R}$  (conserved value)



$f_{\text{DNN}}$ : deep auto encoder trained by  $M_E \times \mathbb{U}(M_E)$

Relationship between time series dataset  $M_E \times \mathbb{U}(M_E)$  and symmetry transformation set  $M_{\text{invariant}}$



【Method 1: Inferring the symmetry (Sec. III A)】

$$M_{\text{invariant}} \approx \forall E \{C \mid [M'_E \times \mathbb{U}'(M'_E)] = f_{\text{DNN}}([M'_E \times \mathbb{U}'(M'_E)])\}$$




【Method 2: Inferring the conservation law (Sec. III B)】

$$[T_l M_{\text{invariant}}]_l = \left( \frac{\partial G_l}{\partial p}, -\frac{\partial G_l}{\partial q} \right) \quad \text{Derived from Noether's theorem. (Sec. II)}$$

# 結果1

モデル

$$x_1^2 + x_2^2 + x_3^2 = r, (x_3 > 0)$$



座標系


$$(x_1, x_2, x_3)$$

変換行列

$$A = \begin{pmatrix} a_{11} & a_{21} & 0 \\ a_{12} & a_{22} & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

# 結果1

サンプリング結果




陰関数の回帰結果

$$\begin{cases} a_{11}^2 + 0.99a_{21}^2 = 1 \\ a_{11}^2 + a_{12}^2 = 1 \\ a_{11}^2 - a_{22}^2 = 0 \\ a_{21}^2 - a_{12}^2 = 0 \\ a_{21}^2 + a_{22}^2 = 1 \\ a_{12}^2 + a_{22}^2 = 1 \end{cases}$$

# 結果2

モデル

$$H_2 = \frac{p^2}{2m}$$



座標系


$$(q, 1, p, 1)$$

変換行列

$$A = \begin{pmatrix} a & b & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & a & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

# 結果2

サンプリング結果



陰関数の回帰結果

$$a = 1.0$$

無限小変換の推定結果

$$\begin{cases} \delta q = \epsilon \frac{\partial a}{\partial b} q + \epsilon \frac{\partial b}{\partial b} = \epsilon \\ \delta p = \epsilon \frac{\partial a}{\partial b} p = 0 \end{cases}$$


保存則

$$G_\delta = 1.0\epsilon p$$

# 結果3

モデル

$$H_3 = \frac{1}{2m} \mathbf{p}^2 + G \frac{mM}{|\mathbf{q}|}$$



座標系


$$(q_1, q_2, p_1, p_2)$$

変換行列

$$A = \begin{pmatrix} a_{11} & a_{21} & 0 & 0 \\ a_{12} & a_{22} & 0 & 0 \\ 0 & 0 & a_{11} & a_{21} \\ 0 & 0 & a_{12} & a_{22} \end{pmatrix}$$

# 結果3

## サンプリング結果



## 陰関数の回帰結果

$$\begin{cases} a_{11}^2 + 0.99a_{21}^2 = 1 \\ a_{11}^2 + 0.98a_{12}^2 = 1 \\ a_{11} - a_{22} = 0 \\ a_{21} + 0.99a_{12} = 0 \\ a_{21}^2 + 1.01a_{22}^2 = 1.01 \\ a_{12}^2 + 1.02a_{22}^2 = 1.02 \end{cases}$$

## 無限小変換の推定結果

$$\delta \mathbf{q} = \varepsilon \begin{pmatrix} \frac{\partial a_{11}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \\ \frac{\partial a_{12}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \end{pmatrix} \mathbf{q} = \varepsilon \begin{pmatrix} \left. \frac{-2 \times 0.99a_{21}}{2a_{11}} \right|_{A=I} & 1 \\ -1/0.99 & \left. \frac{-2a_{21}}{1.01 \times 2a_{22}} \right|_{A=I} \end{pmatrix} \mathbf{q} = \begin{pmatrix} 0 & \varepsilon \\ -1.01\varepsilon & 0 \end{pmatrix} \mathbf{q} \approx \begin{pmatrix} 0 & \varepsilon \\ -\varepsilon & 0 \end{pmatrix} \mathbf{q}$$

$$\delta \mathbf{p} = \varepsilon \begin{pmatrix} \frac{\partial a_{11}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \\ \frac{\partial a_{12}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \end{pmatrix} \mathbf{p} \approx \begin{pmatrix} 0 & \varepsilon \\ -\varepsilon & 0 \end{pmatrix} \mathbf{p}$$


保存則

$$G_\delta = \varepsilon(x_1 p_2 - x_2 p_1)$$


# 結果4

## モデル


Reynolds model [Reynolds et al. 86]



Separation:  
Steer to avoid crowding  
local flockmates




Alignment:  
Steer toward the average  
heading of local flockmates



Cohesion:  
Steer to move toward the average  
position of local flockmates


$$\frac{dv}{dt} = \vec{F}_{separation} + \vec{F}_{alignment} + \vec{F}_{cohesion}$$

Swarm




(A)

Torus




(B)

Dynamic Parallel




(C)

Highly Parallel



(D)

[Couzin et.al 2002]




[Mototake et.al 2015]


# 結果4

## モデル


Reynolds model [Reynolds et al. 86]



Separation:  
Steer to avoid crowding  
local flockmates



Alignment:  
Steer toward the average  
heading of local flockmates



Cohesion:  
Steer to move toward the average  
position of local flockmates

$$\frac{dv}{dt} = \vec{F}_{separation} + \vec{F}_{alignment} + \vec{F}_{cohesion}$$



## 座標系


$$D = \{\tilde{\mathbf{q}}(t_i)_i, \tilde{\mathbf{p}}(t_i)_i, \tilde{\mathbf{q}}(t_i + \Delta t)_i, \tilde{\mathbf{p}}(t_i + \Delta t)_i\}_{i=1}^{N_{RT}}$$
$$(\tilde{\mathbf{q}}, \tilde{\mathbf{p}}) = (q_1 - \bar{q}_1, q_2 - \bar{q}_2, p_1 - \bar{p}_1, p_2 - \bar{p}_2)$$

## 変換行列

$$A = \begin{pmatrix} a_{11} & a_{21} & 0 & 0 \\ a_{12} & a_{22} & 0 & 0 \\ 0 & 0 & a_{11} & a_{21} \\ 0 & 0 & a_{12} & a_{22} \end{pmatrix}$$

# 結果4

## サンプリング結果



## 陰関数の回帰結果

$$\begin{cases} a_{11}^2 + 1.03a_{21}^2 + 0.039a_{11}a_{21} = 1 \\ a_{11}^2 + 1.18a_{12}^2 + 0.077a_{11}a_{12} = 1 \\ a_{11} - 1.016a_{22} + 0.016a_{11}^2 = 0 \\ a_{21} + 1.077a_{12} = 0 \\ -0.038a_{22} + a_{21}^2 + 1.005a_{22}^2 + 0.051a_{21}a_{22} = 0.967 \\ -0.031a_{22} + a_{12}^2 + 0.877a_{22}^2 + 0.056a_{12}a_{22} = 0.845 \end{cases}$$

## 無限小変換の推定結果

$$\delta \mathbf{q} = \varepsilon \begin{pmatrix} \frac{\partial a_{11}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \\ \frac{\partial a_{12}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \end{pmatrix} \mathbf{q} = \varepsilon \begin{pmatrix} \frac{-1.03 \times 2a_{21} - 0.039a_{11}}{2a_{11} + 0.039} & 1 \\ -1/1.077 & \frac{-2a_{21} - 0.051a_{22}}{1.005 \times 2a_{22} - 0.038 + 0.051a_{12}} \end{pmatrix} \bigg|_{A=I} \mathbf{q} = \begin{pmatrix} 0.019\varepsilon & \varepsilon \\ -0.928\varepsilon & 0.026\varepsilon \end{pmatrix} \mathbf{q} \approx \begin{pmatrix} 0 & \varepsilon \\ -\varepsilon & 0 \end{pmatrix} \mathbf{q}$$

$$\delta \mathbf{p} = \varepsilon \begin{pmatrix} \frac{\partial a_{11}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \\ \frac{\partial a_{12}}{\partial a_{21}} & \frac{\partial a_{21}}{\partial a_{21}} \end{pmatrix} \mathbf{p} \approx \begin{pmatrix} 0 & \varepsilon \\ -\varepsilon & 0 \end{pmatrix} \mathbf{p}$$

先行研究 [Couzin et.al 2002]  
で示された結果と一致→

保存則

$$G_\delta = \varepsilon(x_1 p_2 - x_2 p_1)$$

- 時系列データ多様体から，ハミルトン系の対称性の候補が推定可能であることを示した。
- 学習済みのDNNから，時系列データ多様体の対称性を推定できる可能性を示唆した。
- 保存則の数が増えると，ヤコビ行列が正則でなくなる可能性が高まる等，推定が困難になると予想される。
- 位相空間の次元が増えると，サンプリング法による対称性抽出に困難が生じると思われる。

# まとめと今後の展望


- サンプリングによって変換群を推定するのではなく、リー環を直接推定する効率的な手法を開発したい。
- DAEだけでなく他のDNNモデルへの手法適用を試みたい。
- 未知の保存量, あるいは推定が困難とされる保存量の推定を実現したい。

# まとめと今後の展望

- サンプリングによって変換群を推定するのではなく、リー環を直接推定する効率的な手法を開発したい。
- DAEだけでなく他のDNNモデルへの手法適用を試みたい。
- 未知の保存量, あるいは推定が困難とされる保存量の推定を実現したい。


# 他のDNNモデルへの手法適用

## スピン系の相転移状態推定



[Carrasquilla, J. and Melko, R.G., Nature Phys., 2017]

## 時系列データ多様体の抽出



[Lusch, B., Kutz, J.N. and Brunton, S.L., Nature Com., 2018]

# 他のDNNモデルへの手法適用




Figure 1






Figure 2



[Mustafa et al. 19]



# 他のDNNモデルへの手法適用



# 他のDNNモデルへの手法適用

## TOWARDS A GEOMETRICAL UNDERSTANDING OF PHYSICAL PHENOMENA VIA EXTRACTION OF DATA MANIFOLDS USING A GAN

Kotaro Sakamoto (Univ. of Tsukuba), Yuichiro Mori (Univ. of Tokyo), Yoh-ichi Mototake (ISM)




# 皆様と議論したいこと


- 提案手法を適用すると面白そうな物理系について
- 物理学者と機械学習の協業のあり方について

# 大目標

[郡山市ふれあい科学館より, イラスト・高部哲也]



DNN



Data Set

[Y. Mototake, D. thesis: "Geometrical Structures Embedded in High Dimensional Data Sets and Deep Learning", 2016]