

幾何学的な表現学習

福水健次

統計数理研究所

機械学習若手の会（YAML）2024

2024.9.22@ 浜名湖

自己紹介

1989. 京都大学理学部卒業（主として数学）

1989-1998. （株）リコー，研究開発本部
文字認識，音響信号処理，ニューラルネットの研究・開発

1996. 京都大学博士（理学）

1999-2000. 理化学研究所・脳科学総合研究センター・
甘利俊一研究室・研究員 ニューラルネットの統計的研究

2000-現在. 統計数理研究所
機械学習，数理統計の研究

2018－（株）Preferred Networks 技術顧問

2020－JST CREST
「数理知能表現による深層構造学習モデルの革新」



機械学習の現在

- 深層学習を中心とする人工知能技術の革新的発展
 - 画像，自然言語処理，音声，自動運転，ロボット，…
- 深層生成モデル
 - 画像生成
 - Stable Diffusion, Midjourney, …
 - 大規模言語モデル
 - ChatGPT, Gemini, LLaMa, o1, …
 - 動画生成
 - Sora



Stability.AI, Stable Diffusion XL

```
python
import numpy as np
arr = np.array([0, 1, 0, 2, 3, 0])
indices = np.nonzero(arr)[0]
print(indices)
```

Output:

```
csharp
[1 3 4]
```


In this example, the "arr" variable contains an array with some zero and non-zero values. The "np.nonzero()" function is used to find the indices of the non-zero elements in the array. The results are stored in the "indices" variable.



OpenAI, Sora

人工知能 vs 数学的知

- 深層学習による人工知能： 経験（データ） 的知識獲得
 - Large Data / Large Model
 - データからの知識獲得
 - 表現学習：Implicitな情報表現
大量データにより
有効な表現を自動獲得



Dr Alan D. Thompson, LifeArchitect.ai (Mar/2023).

- 数学的知：演繹的知

科学的知識は，伝統的には
「数学」により記述されてきた

e.g.

微分方程式

$$\rho \frac{D\mathbf{u}}{dt} = -\nabla p + \mu \nabla^2 \mathbf{u} + \frac{1}{3} \mu \nabla (\nabla \cdot \mathbf{u}) + \rho \mathbf{g}$$


代数

構造を抽象化する

$$\begin{array}{ccccccc} A & \xrightarrow{f} & B & \xrightarrow{g} & C & \longrightarrow & 0 \\ \downarrow a & & \downarrow b & & \downarrow c & & \\ 0 & \longrightarrow & A' & \xrightarrow{f'} & B' & \xrightarrow{g'} & C' \end{array}$$

Mathematics is the language
with which God has written
the universe

– Galileo Galilei



- 人工知能＋数学的知

数学的知により，経験的知である人工知能技術をどのように変革できるか？

代数構造，幾何学，微分方程式，etc

講演の概要

1. イントロ
2. 対称性と群の作用
3. 機械学習と群作用
4. 群の表現
5. Neural Fourier Transform
6. まとめ

対称性と群の作用

対称性

デザイン




葵の御紋




Cloisters, University of Glasgow


自然界



形態の対称性




結晶格子



[Thürlemann et al. *J. Chem. Theory Comput.* 2022]

原子配置/ポテンシャル


対称性をとらえる変換



鏡映



回転



平行移動

群と群の作用

- 群： 対称性とそれをとらえる変換を数学的に定義したもの
定義 群 (group)

空でない集合 G に演算が定義されている(積で表記)とき, G が 群 であるとは,

- (1) (結合律) $(ab)c = a(bc)$ for any $a, b, c \in G$.
- (2) (単位元の存在) $e \in G$ があって, $ae = ea = a$ for any $a \in G$.
- (3) (逆元の存在) 任意の $a \in G$, に対し, $a^{-1} \in G$ があって $aa^{-1} = a^{-1}a = e$.

例1) $(\mathbb{Z}^n, +), (\mathbb{R}^n, +)$ 加法に関して可換な群 (Abel群) . $\mathbf{a} + \mathbf{b} = \mathbf{b} + \mathbf{a}$.

例2) $GL(\mathbb{R}^m)$ 一般線形群 (可逆な $m \times m$ 行列全体) 積に関して群.
非可換 $AB \neq BA$.
部分群 $O(m)$ 回転群

- 群の作用


定義

G : 群, X : 集合.

G の X への群作用 とは, 各 $g \in G$ に対して X の変換 $g \circ$ が定まって

i) $e \circ x = x$ ($e \in G$ は単位元)

ii) $(hg) \circ x = h \circ (g \circ x)$



- 典型的な例：

1) $GL(\mathbb{R}^m)$ の $\mathbb{R}^m$ への標準的な作用 $A \circ x := Ax$ (行列とベクトルの積)

$O(m)$: 回転群

2) シフト: $G = (\mathbb{R}^m, +)$ の $\mathbb{R}^m$ 自身への作用 $a \circ x := x - a$.

3) $\mathcal{F} = \{f: G \rightarrow \mathbb{R}^m\}$ (群上の写像)

$$L_g(f) := [h \mapsto f(g^{-1}h)]$$

L_g は G の $\mathcal{F}$ への作用を定める.

不変性, 同変性

定義.

群 G が集合 X と Y に作用. 写像 $\varphi: X \rightarrow Y$.

- φ が G の作用に対して 不変 (invariant) とは,



$$\varphi(g \circ x) = \varphi(x)$$

が任意の $g \in G, x \in X$ に対して成り立つこと.

- φ が G の作用に対して 同変 (equivariant) とは

$$\varphi(g \circ x) = g \circ \varphi(x)$$


が任意の $g \in G, x \in X$ に対して成り立つこと.



機械学習における群作用


不変性

object classification



同変性

segmentation



From "Groups, Representations & Equivariant maps" by Maurice Weiler (University of Amsterdam)

機械学習と群作用

不変性/同変性を用いた深層学習

不変性/同変性：多くの有用なモデルで利用

- **Architecture:** モデル構造により同変性実現
 - Convolutional Neural Network (CNN):
- **Data augmentation:** データ拡張に利用
 - データを変換により拡張して学習する.
 - 不変な識別機の学習
 - 「自己教師あり学習」. 変換したものは近い表現

これらのアプローチでは群 G はknown





Fig. 2. Architecture of LeNet-5, a Convolutional Neural Network, here for digits recognition. Each plane is a feature map, i.e. a set of units whose weights are constrained to be identical.

LeCun 1998




SimCLR


• 同変性に基づく表現学習

同変になるように学習を行うことによってよい表現を得る。
今日の本題

- Meta-sequential prediction (Miyato, Koyama, Fukumizu NeurIPS 2022)
- Neural Fourier Transform (Koyama, Fukumizu, Hayashi, Miyato ICLR 2024)
- Neural Isometries. (Mitchel et al arXiv 2024)
- Latent Space Symmetry Discovery. (Yang et al ICML 2024)





Neural Isometry



Yang et al ICML 2024

Convolutional Neural Networks

- CNN (Wei Zhang et al 1988; Yann LeCun 1989)
 - 平行移動同変性を実現するNNアーキテクチャ. 画像入力を想定
 - 畳み込み層+ Pooling層
Backpropで学習.
 - 生物の初期視覚野の神経回路網
モデルに触発されている.
- オリジン: Neocognitron (Fukushima 1980)
Backprop は使われていなかった.



Kunihiko Fukushima 1979

画素 $[i, j]$ の値 $f[i, j]$

- 畳み込み層


- 2D グレイスケール画像 ($W \times H$)

$\psi_{[a,b]}$: 空間フィルタ (3×3 or 5×5).

$$h_{[i,j]}^{out} = \sum_{i-a \in \{0, \pm 1\}} \sum_{j-b \in \{0, \pm 1\}} \psi_{[i-a, j-b]} f_{[a,b]}^{In}$$

$$f_{[i,j]}^{out} = \phi(h_{[i,j]}^{out} + \theta) \quad \phi: \text{活性化関数}$$

- 畳み込み層, Pooling層は同変写像



Group equivariant Convolutional Networks

(Cohen & Welling ICML 2016)

- G-CNN: さまざまな群 G の作用に対して同変なCNN


- CNN

- 画像: 2次元格子からの写像.

$$f: \mathbb{Z}^2(\text{画素}) \rightarrow \mathbb{R}^3(\text{RGB}).$$

- $\mathbb{Z}^2$ のシフトに対してCNNは同変.

$$\Psi_{\text{Conv}}(f(\cdot - s)) = (\Psi_{\text{Conv}}f)(\cdot - s).$$




- G-CNN

- 入力信号: 一般の群 G からの写像.

$$f: G \rightarrow \mathbb{R}^K.$$

- G から決まるシフト作用に関して同変.



$$\Psi_{\text{Conv}}(L_g f) = L_g(\Psi_{\text{Conv}}f).$$



<https://github.com/QUVA-Lab/e2cnn>

自己教師あり学習：データ拡張

- 教師ラベルのない画像データからの特徴学習
- データ拡張：色変化，切り抜き，回転など（群作用とは限らない）
- Contrastive Learning
元データと変換データは近い出力を，他の画像は遠い出力なるよう学習。
- SimCLR [Chen et al 2020],
Contrastive Predictive Coding [van der Ord et al 2018] etc



群の表現

群の表現 群の線形な作用

- 群の表現

群の性質を線形変換を通して解析するための数学的方法.

定義. G : 群. V : ベクトル空間. $GL(V)$: V 上の可逆線形変換全体.


$$\rho: G \rightarrow GL(V)$$

が群 G の V 上の 表現 であるとは, ρ が 群準同型 であること, すなわち,

$$\rho(e) = I_V, \quad \rho(ab) = \rho(a)\rho(b) \quad (\forall a, b \in G).$$

ρ は G の V への 線形な作用 を定める.

$$x \mapsto \rho(a)x$$



$a \cdot b$

ρ ↓

$$\begin{pmatrix} \rho(a) \end{pmatrix} \begin{pmatrix} \rho(b) \end{pmatrix}$$


行列

正則表現

関数のシフトを表す. CNNで使われている.

定義. G : 群. $V := \{f: G \rightarrow \mathbb{R}\}$ G 上の関数全体.

$$L_g: V \rightarrow V, f \mapsto [h \mapsto f(g^{-1}h)]$$



L_g は G の表現 (正則表現と呼ぶ) ,
すなわち

- 線形写像, $(L_g(c_1 f_1 + c_2 f_2))(g^{-1} \cdot) = c_1 L_g(f_1) + c_2 L_g(f_2)$
- $L_{gh} = L_g \circ L_h$.

例) $G = (\mathbb{R}^d, +)$, $a \in G$. $(L_a f)(x) = f(-a + x) = f(x - a)$.

群表現の分解

定義 (**既約表現**) 群 G の表現 (ρ, V) に対し, $\{0\}$ でも V でもない部分空間
 $W \subset V$ があつて $\rho(g)W \subset W$ を満たす (したがつて W への制約がまた表現になる) とき, (ρ, V) は**可約**であるという. 可約でないとき**既約**という.

$$\text{可約} \quad \begin{pmatrix} A(g) & B(g) \\ \textcolor{red}{0} & D(g) \end{pmatrix} \begin{pmatrix} w \\ 0 \end{pmatrix} = \begin{pmatrix} A(g)w \\ 0 \end{pmatrix}$$

定義 (**直和**) 群 G の表現 $(\rho_1, V_1), (\rho_2, V_2)$ の直和:

$$\begin{aligned} \rho_1 \oplus \rho_2: G &\rightarrow V_1 \oplus V_2, \\ g &\mapsto \rho_1(g) \oplus \rho_2(g). \end{aligned}$$

$$\rho(g) = \begin{pmatrix} \rho_1(g) & 0 \\ 0 & \rho_2(g) \end{pmatrix}$$

- 定義 表現 ρ が完全可約 (半単純) とは, 既約表現の直和と同値になること.

$$\rho \cong \rho_1 \oplus \rho_2 \oplus \cdots \oplus \rho_k$$

共通の基底をとって, 任意の g に対して同時ブロック対角化できる場合.

$$\rho(g) = P \begin{pmatrix} A_1(g) & 0 & \cdots & 0 \\ 0 & A_2(g) & \ddots & 0 \\ \vdots & & \ddots & \vdots \\ 0 & & \cdots & A_k(g) \end{pmatrix} P^{-1}$$

基底変換 P は g に非依存
各 $A_i(g)$ は既約表現


- 以下のクラスは, 任意の有限次元表現が完全可約となる.
 - 有限群
 - 局所コンパクトアーベル群 ($SO(2)$, etc)
 - コンパクトLie群 ($O(n)$, etc).
- 完全可約でない例: ユークリッド運動群 $E(n)$

$$E(n) = \left\{ \begin{bmatrix} A & b \\ 0 & 1 \end{bmatrix} \mid A \in O(n), b \in \mathbb{R}^n \right\}$$


$$\begin{bmatrix} A & b \\ 0 & 1 \end{bmatrix} \begin{pmatrix} x \\ 1 \end{pmatrix} = \begin{pmatrix} Ax + b \\ 1 \end{pmatrix}$$

Neural Fourier Transform: データからの学習によるFourier変換

Miyato, Koyama, Fukumizu. NeurIPS 2022;
Koyama, Fukumizu., Hayashi, Miyato. ICLR 2024



Takeru Miyato
(U Tübingen/
Preferred Networks)




Masanori Koyama
(Preferred Elements)



Kohei Hayashi
(Preferred Elements)

群作用を用いた系列データからの表現学習

(Miyato, Koyama, Fukumizu, NeurIPS 2022; Koyama, Fukumizu, Hayashi, Miyato, ICLR 2024)



• 潜在的な群作用を用いた表現学習


- 作業仮説：「動き」の中に有効な特徴が潜在している

- 群作用から生じると仮定する

ペア $(x, g \circ x)$,
系列 $(x, g \circ x, g^2 \circ x, \dots, g^T \circ x)$
からの表現学習

- 潜在的な群作用. 群は知らない

- 画像自体への変換とは限らない
- 直接観測できるとは限らない



3D空間での回転



非線形な観測（魚眼レンズ）

データからの未知/既知の対称性の抽出

最も基本の問題設定：教師なしの表現学習

- データの生成モデル：群作用による定常な系列データ

G : 群, $\mathcal{S}$ に作用.

系列: $\mathbf{s} = (s_0, s_1, s_2, \dots, s_T)$.

$$s_t = g^t \circ s_0, \quad \mathbf{s} = \mathbf{s}(g, s_0)$$

$g \in G$ は系列ごとに異なって
よいが系列内では一定.


- 多数の系列データからの教師無し学習

G も $g \in G$ も作用も知らない

$$\mathbf{s}^{(1)} = \mathbf{s}(g^{(1)}, s_0^{(1)}) \quad \text{e.g. } g^{(1)} = (15^\circ \text{回転}, (-2,1) \text{シフト}, \Delta \text{RGB})$$



$$\mathbf{s}^{(2)} = \mathbf{s}(g^{(2)}, s_0^{(2)})$$



回転, 平行移動, 色の回転

初期画像 s_0 と群の元 $g \in G$ を決めると,
ひとつの系列 $\mathbf{s}$ が生成される.

Autoencoderによる線形な遷移則の学習

Meta Sequential Learning (MSP)

$$\mathbf{s} = (s_t)_{t=0}^T, \quad s_{t+1} = g \circ s_t$$

- Autoencoder :

Encoder $\Phi: \mathcal{X} \rightarrow \mathbb{R}^{a \times m}$, Decoder $\Psi: \mathbb{R}^{a \times m} \rightarrow \mathcal{X}$

- 潜在表現の遷移則は**線形** :
行列 M_s 系列依存.

$$\begin{bmatrix} M_s \end{bmatrix} \begin{bmatrix} \Phi(s) \end{bmatrix}_a^m$$

- 潜在空間は行列 :
表現能力を落とさずに M_s の次元を小さくできる.

- M_s, Φ, Ψ の学習


$$\min_{M_s} \|M_s \Phi(s_t) - \Phi(s_{t+1})\|^2$$

[同変性]

$$\min_{\Phi, \Psi} \sum_{\ell} \left\| \Psi \left(M_s^{\ell} \Phi(s_t) \right) - s_{t+\ell} \right\|^2$$

[Prediction]

モデル



Φ を固定すると,
最小 2 乗誤差で M が決まる.

変換行列の既約分解

- 変換行列 M_s は系列 s ごとに異なる
変換 g に依存, $M(g)$ と書ければ群の表現
- 表現の既約分解 $\rightarrow \{M_s\}_s$ の同時ブロック対角化
系列に依存しない基底変換により, 同時にブロック対角化を行う
各ブロックは既約表現 $\rightarrow$ 分解された表現.



$$\begin{bmatrix} P \end{bmatrix} \left\{ \begin{array}{c} M_{s_1} \\ M_{s_2} \\ M_{s_3} \\ M_{s_4} \end{array} \right\} \begin{bmatrix} P^{-1} \end{bmatrix} = \begin{array}{cccc} UM_{s_1}U^{-1} & UM_{s_2}U^{-1} & UM_{s_3}U^{-1} & UM_{s_4}U^{-1} \\ \begin{bmatrix} \text{block} & 0 \\ 0 & \text{block} \end{bmatrix} & \begin{bmatrix} \text{block} & 0 \\ 0 & \text{block} \end{bmatrix} & \begin{bmatrix} \text{block} & 0 \\ 0 & \text{block} \end{bmatrix} & \begin{bmatrix} \text{block} & 0 \\ 0 & \text{block} \end{bmatrix} \end{array}$$

基底変換 P は共通

表現論による Disentanglement

実験 1: 表現学習としての有効性


- Encoder出力 $\Phi(x)$ を用いて線形識別タスクを解く
MNIST 画像“4”の系列データのみで学習 $\rightarrow$ “0”, ..., “9”. 10クラスの識別を解く.




* SimCLR, CPC: 自己教師あり学習

- 実験 2 : 既約分解による Disentanglement


Before SBD After SBD



(1) Floor hue (2) Wall hue (3) Object hue (4) Scale (5) Orientation



同時ブロック対角化により得られたブロック



各ブロックのみを取り出した M による生成結果

Fourier変換

- (復習) 古典的なFourier変換

$\mathbb{S}^1 \cong [0,1]$ 上のFourier変換 (Fourier級数展開)

$$\hat{f}_n = \Phi(f)(n) = \int_0^1 e^{-2\pi\sqrt{-1}nx} f(x)dx, \quad f(x) = \frac{1}{2\pi} \sum_{n=-\infty}^{\infty} e^{2\pi\sqrt{-1}nx} \hat{f}_n$$

$\mathbb{S}^1$ は加法群, f は群上の関数

- Fourier変換はより一般の群に対して定義可能

- 可換群 (局所コンパクトアーベル群) : ほぼそのまま拡張可能

$$\Phi: L^2(G) \rightarrow L^2(\hat{G}), \quad f \mapsto \hat{f}(\rho) := \int_G \overline{\rho(x)} f(x) dx.$$

$\rho(x)$ は既約表現 (常に1次元) ($\mathbb{S}^1$ の例では, ある n に対する $e^{2\pi\sqrt{-1}nx}$ に相当)

- コンパクト群
Fourier変換

$$\Phi(f) = \hat{f}(\rho) := \int_G f(g) \rho(g)^* dg = \int_G f(g) \rho(g^{-1}) dg$$

$[\rho] \in \hat{G} := \{G \text{ の 既約ユニタリ表現の同値類} \}$ 周波数の空間

• $\rho(g)$ は一般に行列値関数. $d_\rho := \dim \rho$

- Fourier inversion


$$f(g) = \sum_{[\rho] \in \hat{G}} d_\rho \text{Tr}[\rho(g) \hat{f}(\rho)]$$

Fourier変換の同変性

- Fourier変換の同変性

- $S^1 \cong [0,1]$ 上のシフト $L_a f := f(\cdot - a)$ に対するFourier変換

$$\begin{aligned}\Phi(L_a f) &= (e^{2\pi\sqrt{-1}an} \hat{f}_n) = \begin{pmatrix} \ddots & \dots & 0 \\ \vdots & e^{2\pi\sqrt{-1}an} & \vdots \\ 0 & \dots & \ddots \end{pmatrix} \begin{pmatrix} \vdots \\ \hat{f}_n \\ \vdots \end{pmatrix} \\ &= M(a) \Phi(f)\end{aligned}$$



- $S^1 \ni a \mapsto M(a)$ は加法群 S^1 の表現 (線形作用)
- Φ は同変 (右の図式が可換)
- 同変性は一般のFourier変換に対して成り立つ.

Neural Fourier Transform

- 提案法はFourier変換の拡張と考えられる

群 G が空間 x に作用しているとき、以下の写像をデータから学習している。

$$L_g x \approx \underbrace{\Psi \circ M(g) \circ \Phi(x)}_{\text{Fourier逆変換}} = \underbrace{\Psi \circ P^{-1}}_{\text{Fourier逆変換}} \circ \overset{\text{ブロック対角 (既約表現)}}{\begin{pmatrix} \rho_1(g) & & 0 \\ & \rho_2(g) & \\ 0 & & \ddots \end{pmatrix}} \circ \underbrace{P \circ \Phi(x)}_{\text{Fourier変換}}.$$

$$x \approx \Psi \circ P^{-1} \circ P \circ \Phi(x) \quad \text{Fourier inversion formula}$$


Neural Fourier Transform:

データからの学習による、任意のデータ型に対するFourier変換

- 「潜在的空間」への群の作用でOK.
- 群上の関数ではなく、データに対するFourier変換
- データの記述に必要な周波数/既約成分のみを自動獲得

• さまざまなシナリオ

	群 G	群の元 g	作用	$M(g)$ の推定
U-NFT	Unknown	Unknown	Unknown	MSPで学習
G-NFT	Known	Unknown	Unknown	調和関数の関数系利用
g-NFT	Known	Known	unknown	調和関数 Φ, Ψ のみ学習




未知の非線形変換による観測（魚眼レンズ）

潜在空間（一定のシフト）観測されない


1次元信号の場合

周波数 5 個の
混合信号




未知の非線形観測 $\left(\frac{t}{128}\right)^3$

非線形観測
信号



**U-NFT
(MSPで学習)**



正しい周波数を推定

2次元画像の場合



予測画像系列

真の系列

• g -NFT : 2D画像1枚からの3次元生成



学習 : 3D-CGデータを観測した **2D画像データのみ** による g -NFT学習

2D画像ペアと 3D回転データ (S, S', R) $R \in SO(3)$, S, S' : 2D画像

$M(g)$ 球面調和関数を仮定. Encoder, decoderのみ学習

使用時 : **訓練データにない 2D画像 1枚**

→ 任意の 3次元回転を施した画像を生成



まとめ

- 群作用を利用する深層学習
 - アーキテクチャ: G-CNN
 - データ拡張: 不変学習, 自己教師あり学習
 - 同変性による表現学習: 新しい方向性
- Neural Fourier Transform
 - 潜在空間で線形作用になるような学習
 - 群の作用を知らなくても適用可能
 - データ駆動の非線形Fourier変換が実現可能
 - 任意のデータ型に対するFourier変換
 - 必要な周波数を自動抽出
 - 応用 (今後)
 - シミュレーションで学習 → 静止 2 D画像の物体を自由に動かす
 - 変微分法方程式系の特徴学習

References

- Online materials
 - U Amsterdam - An Introduction to Group Equivariant Deep Learning
<https://uvagedl.github.io/>
- Textbooks on Group Theory
 - [Group Theory] J.J. Rothman. An Introduction to the Theory of Groups. Springer 1995.
 - [Representation Theory] W. Fulton, J. Harris. Representation Theory. Springer 2004
 - [Fourier Analysis] W. Rudin. Fourier Analysis on Groups. John Wiley & Sons, 1991

• Papers

- Fukushima, Kunihiro (1980). [“Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position”](#). *Biological Cybernetics* **36** (4): 193–202. [doi:10.1007/BF00344251](#)
- Zhang, Wei (1988). [“Shift-invariant pattern recognition neural network and its optical architecture”](#). *Proceedings of annual conference of the Japan Society of Applied Physics*.
- Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. D. Jackel, [Backpropagation Applied to Handwritten Zip Code Recognition Archived](#) 2020-01-10 at the [Wayback Machine](#); AT&T Bell Laboratories
- T. Cohen and M. Welling. Group Equivariant Convolutional Networks. ICML 2016
- Lafarge, M. W., Bekkers, E. J., Pluim, J. P. W., Duits, R., & Veta, M. (2021). Roto-translation equivariant convolutional networks: Application to histopathology image analysis. *Medical Image Analysis*, *68*, 101849. <https://doi.org/https://doi.org/10.1016/j.media.2020.101849>
- M. Weiler and G. Cesa. General E(2) - Equivariant Steerable CNNs. NeurIPS 2019

- T. Miyato, M. Koyama, K. Fukumizu. Unsupervised Learning of Equivariant Structure from Sequences. NeurIPS 2022
- M. Koyama, K. Fukumizu, K. Hayashi, T. Miyato. Neural Fourier Transform: A General Approach to Equivariant Representation Learning. ICLR 2024
<https://openreview.net/forum?id=eOCvA8iwXH>
- Thomas W. Mitchel, Michael Taylor, Vincent Sitzmann. Neural Isometries: Taming Transformations for Equivariant ML. [arXiv:2405.19296](https://arxiv.org/abs/2405.19296) [cs.CV]
- [Jianke Yang](#), [Nima Dehmamy](#), [Robin Walters](#), [Rose Yu](#). Latent Space Symmetry Discovery. ICML 2024 <https://openreview.net/forum?id=xbXASfz8MD>

Appendix

- 例: $\mathfrak{S}_3$ の既約表現

1) 自明な表現 (1 dim)


$$\rho_e(g) = 1$$

2) Alternating representation (1 dim)

$$\rho_{alt}(g) = \text{sgn}(g)$$

3) 標準表現 (2 dim)

$$\begin{cases} \rho_{st}(\sigma) = \begin{pmatrix} \cos(-2/3\pi) & -\sin(-2/3\pi) \\ \sin(-2/3\pi) & \cos(-2/3\pi) \end{pmatrix} = \begin{pmatrix} -\sqrt{3}/2 & 1/2 \\ -1/2 & -\sqrt{3}/2 \end{pmatrix} \\ \rho_{st}(\tau) = \begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix} \end{cases}$$



$\mathfrak{S}_3$ の既約表現は上の3つだけであることが知られている. (See, e.g., Fulton Harris)

G-CNNの目的

$$E(n) = \left\{ \begin{bmatrix} A & b \\ 0 & 1 \end{bmatrix} \mid A \in O(n), b \in \mathbb{R}^n \right\}$$

$$\begin{bmatrix} A & b \\ 0 & 1 \end{bmatrix} \begin{pmatrix} x \\ 1 \end{pmatrix} = \begin{pmatrix} Ax + b \\ 1 \end{pmatrix}$$

- Symmetries

- 画像の多くの特徴はEuclid運動群（回転＋シフト）に対して不変($E(2)$, $SE(2)$).

- 医療画像データ：回転やシフトはあまり意味を変えない.

c.f., 自然画像(部屋, 道路など), 文字画像 (アルファベット, 数字など)は回転で意味が変わる.

- 3D データ/360度画像 ($SO(3)$, $E(3)$)

- 3D スキャナ, レンダリング.

- 360度カメラ.



<https://github.com/QUVA-Lab/e2cnn?tab=readme-ov-file>

- グラフ

- 置換に関して不変

- 3次元内のグラフ構造, e.g., 分子 ($SE(3)$)

