

# 物理シミュレーションのための 同変グラフニューラルネットワーク

Deep learning and Physics

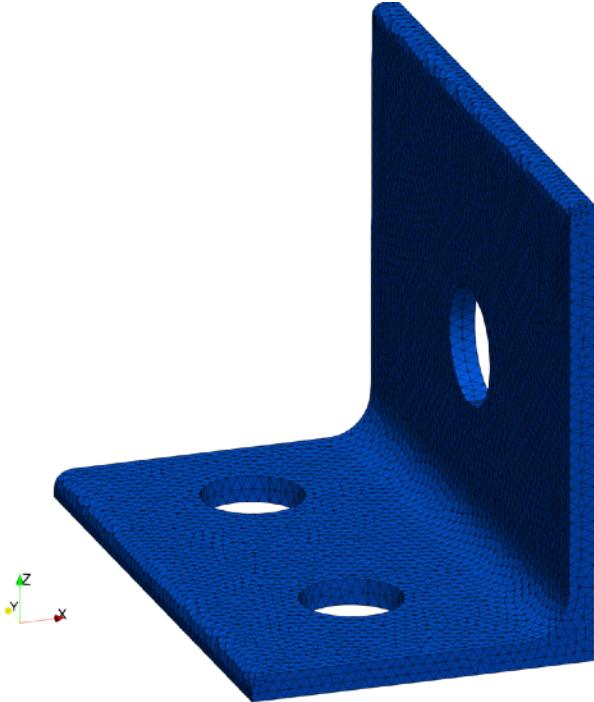
2021 年 4 月 22 日



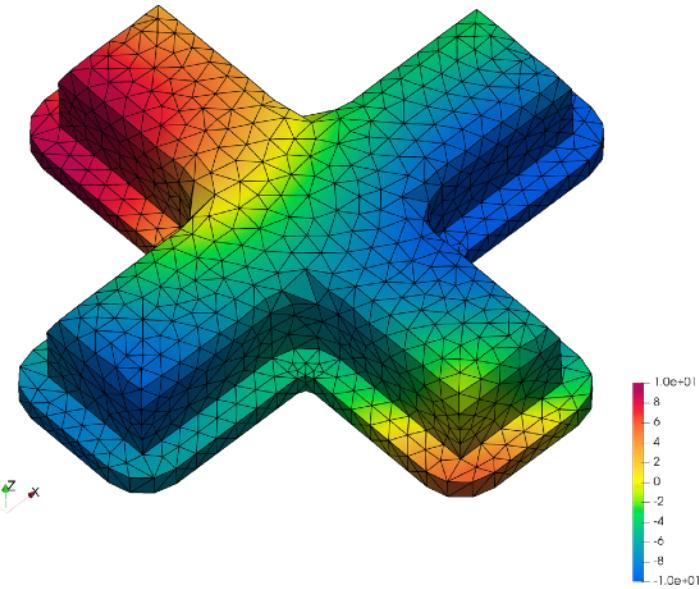
堀江正信

株式会社科学計算総合研究所  
筑波大学システム情報工学研究群

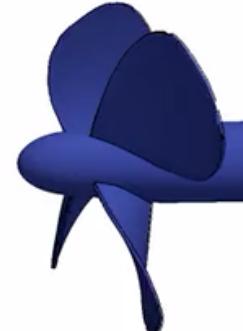
# 背景：物理シミュレーションを軽量化したい



構造



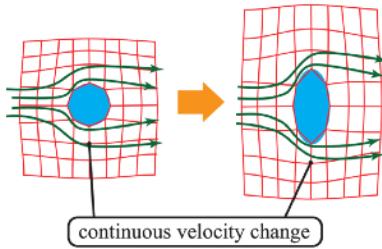
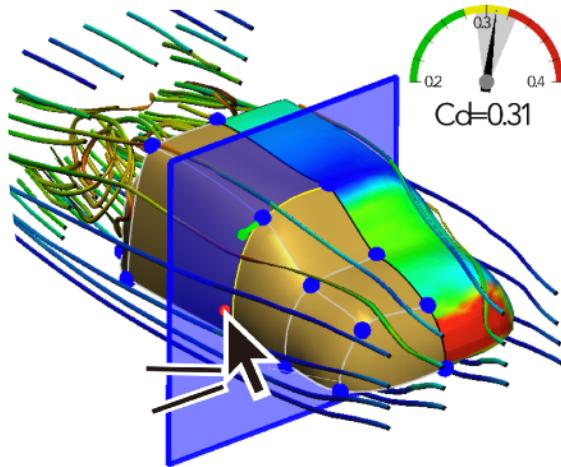
熱



流体

- ・シミュレーションは製品の物理特性の評価において重要
  - ・計算時間が長く、シミュレーションを用いた最適化が困難な場合がある
- 軽量なモデル（サロゲートモデル）で重いシミュレーションを置き換えたい

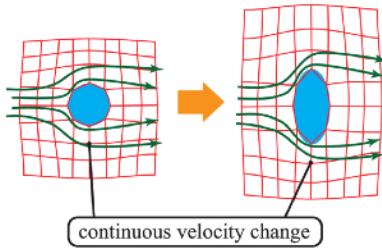
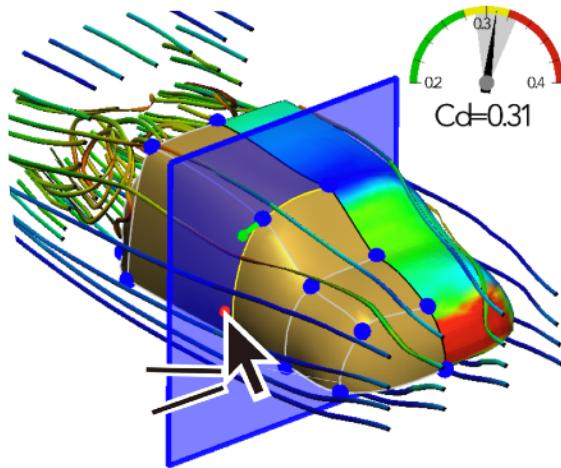
# 関連研究：物理シミュレーションの機械学習



Umetani+ 2018

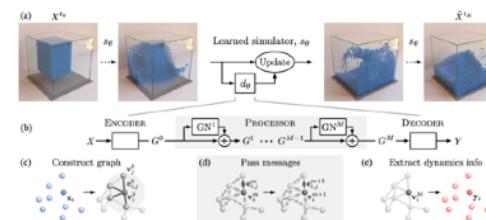
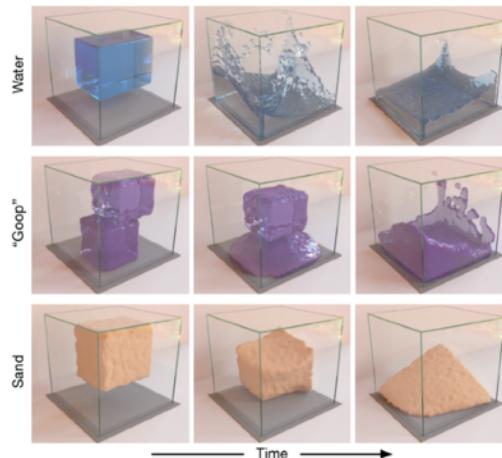
- リアルタイムで  
車体の空力性能予測
- メッシュ構造固定

# 関連研究：物理シミュレーションの機械学習



Umetani+ 2018

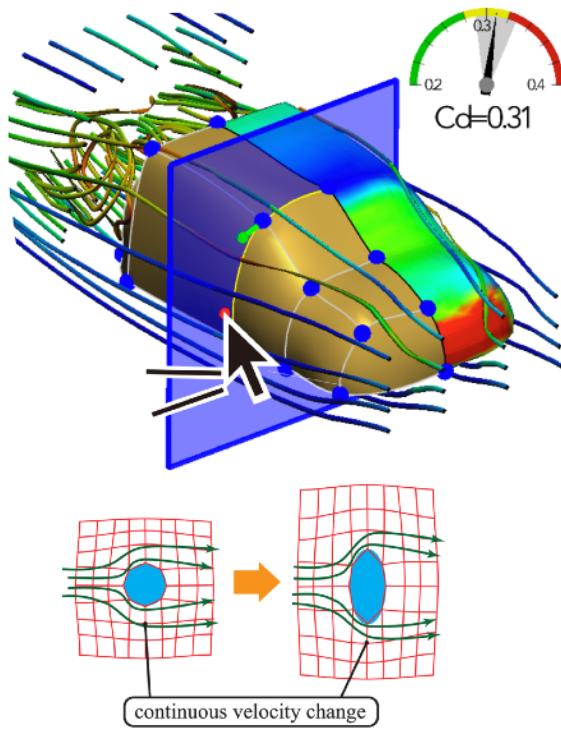
- リアルタイムで車体の空力性能予測
- メッシュ構造固定



Sanchez-Gonzalez+ 2020

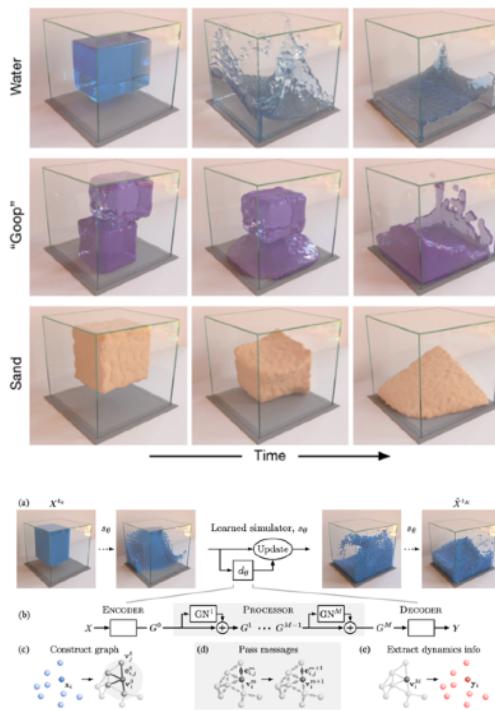
- 任意点群での学習
- 高速化は未達成

# 関連研究：物理シミュレーションの機械学習



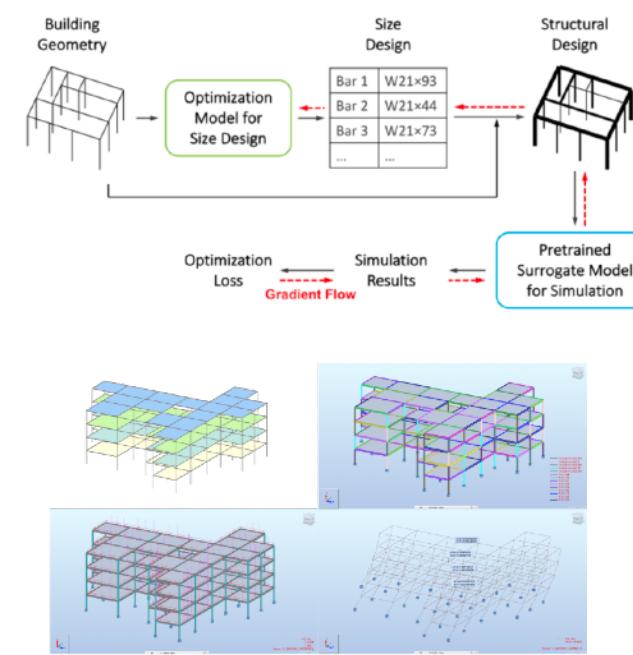
Umetani+ 2018

- リアルタイムで車体の空力性能予測
- メッシュ構造固定



Sanchez-Gonzalez+ 2020

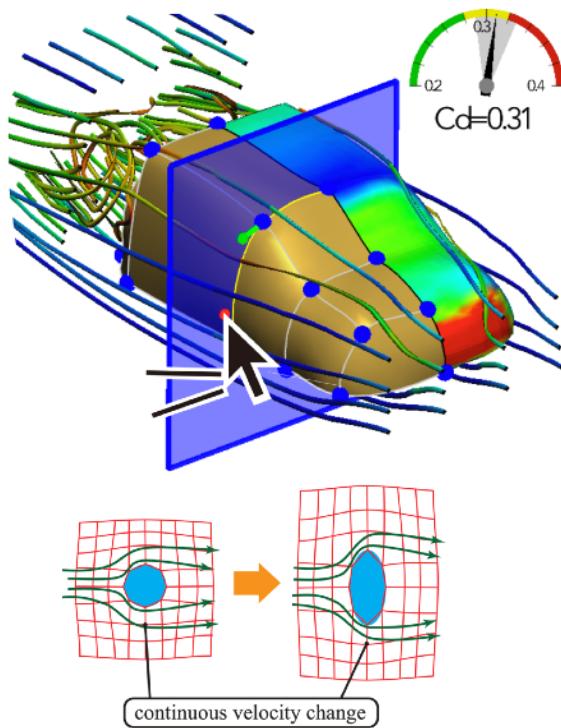
- 任意点群での学習
- 高速化は未達成



Chang+ 2020

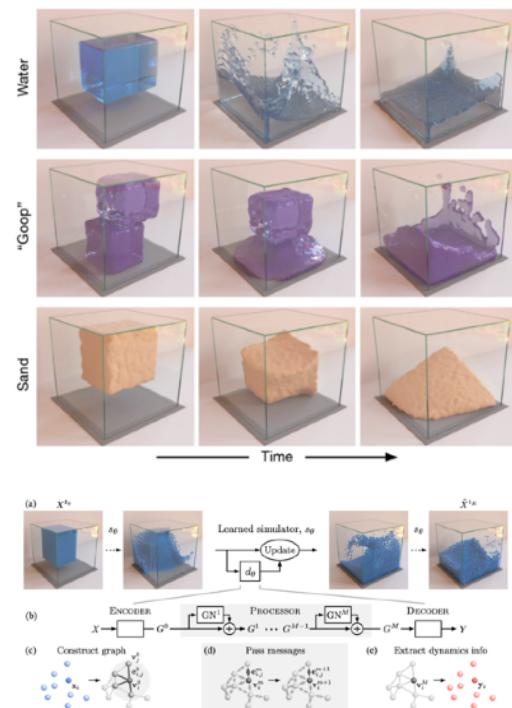
- 任意梁構造での学習
- 梁部材選定の最適化

# 関連研究：物理シミュレーションの機械学習



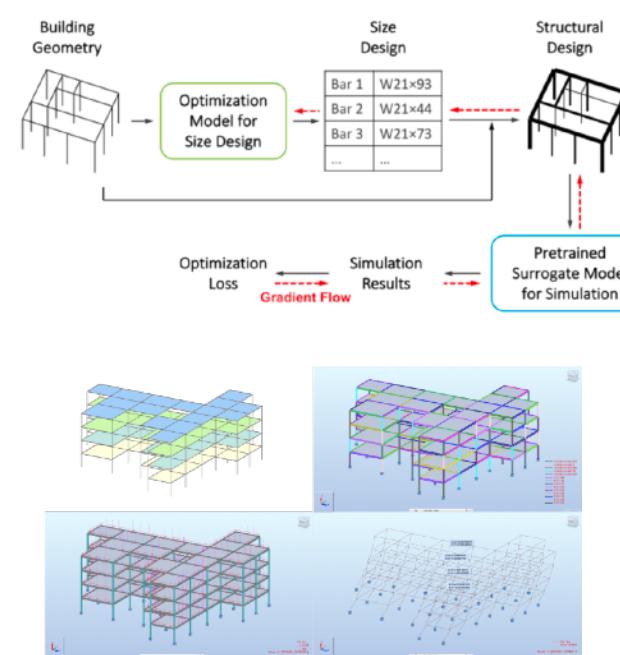
Umetani+ 2018

- リアルタイムで車体の空力性能予測
- メッシュ構造固定



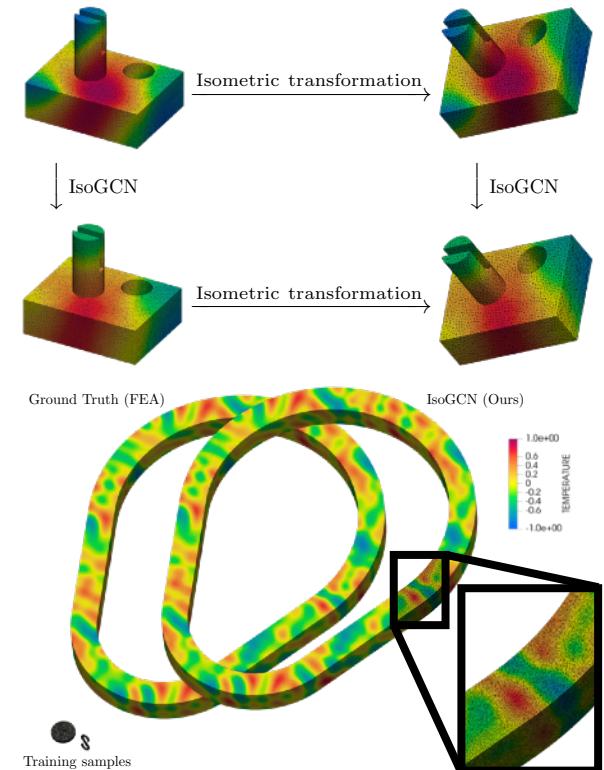
Sanchez-Gonzalez+ 2020

- 任意点群での学習
- 高速化は未達成



Chang+ 2020

- 任意梁構造での学習
- 梁部材選定の最適化

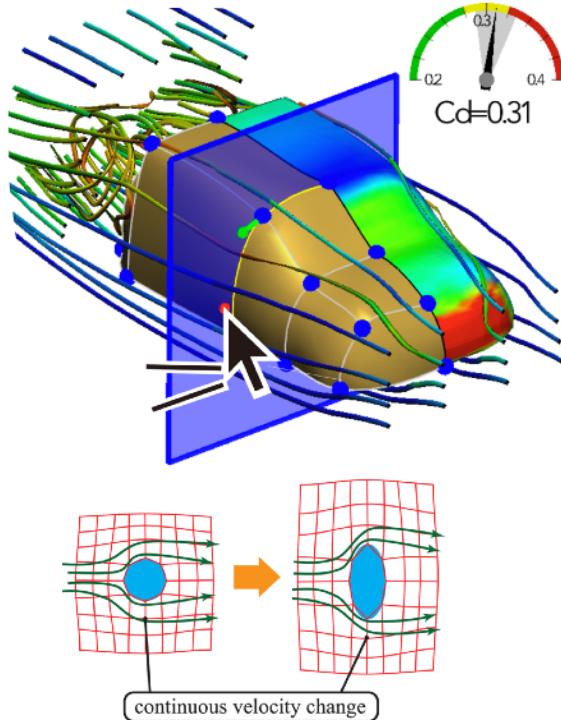


Horie+ 2020 (IsoGCN)

- 任意メッシュでの学習
- 高速化を達成
- 物理現象の対称性を考慮

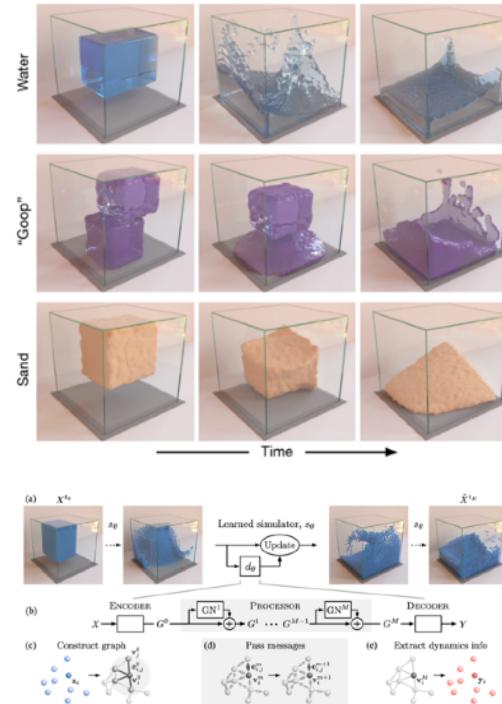
# 関連研究：物理シミュレーションの機械学習

→ Graph Neural Network の適用



Umetani+ 2018

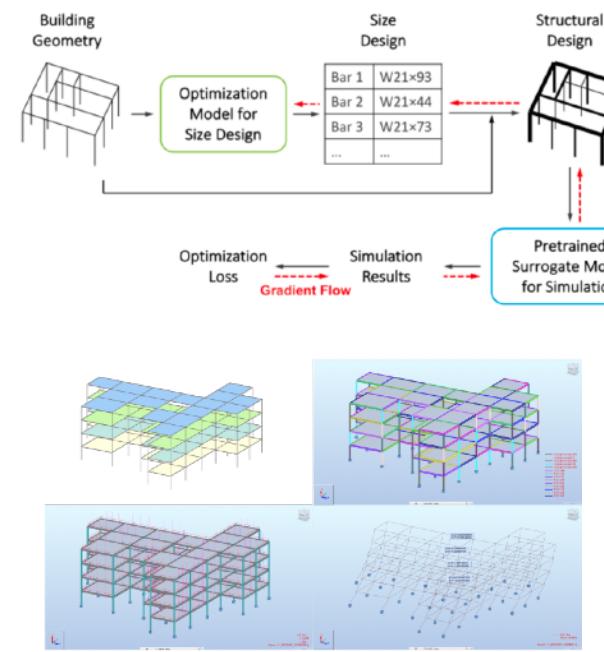
- リアルタイムで車体の空力性能予測
- メッシュ構造固定



Sanchez-Gonzalez+ 2020

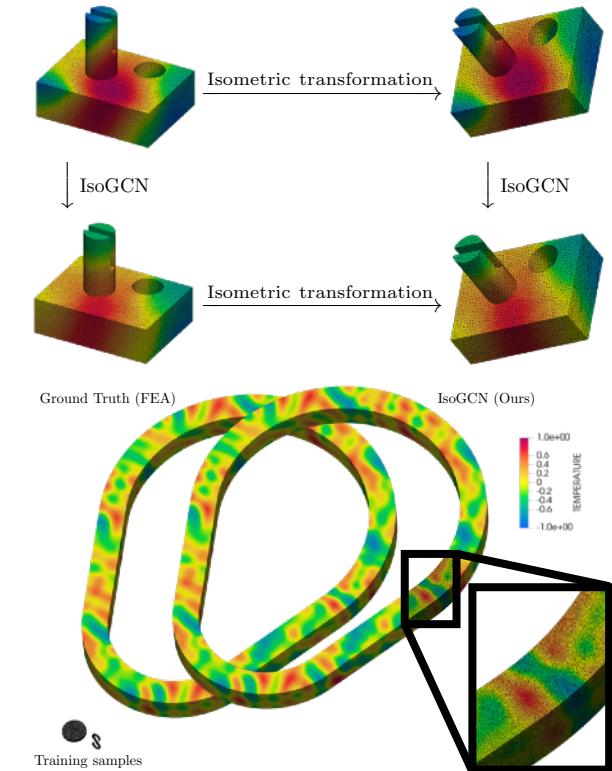
- 任意点群での学習
- 高速化は未達成

→ 同変性の導入



Chang+ 2020

- 任意梁構造での学習
- 梁部材選定の最適化



Horie+ 2020 (IsoGCN)

- 任意メッシュでの学習
- 高速化を達成
- 物理現象の対称性を考慮

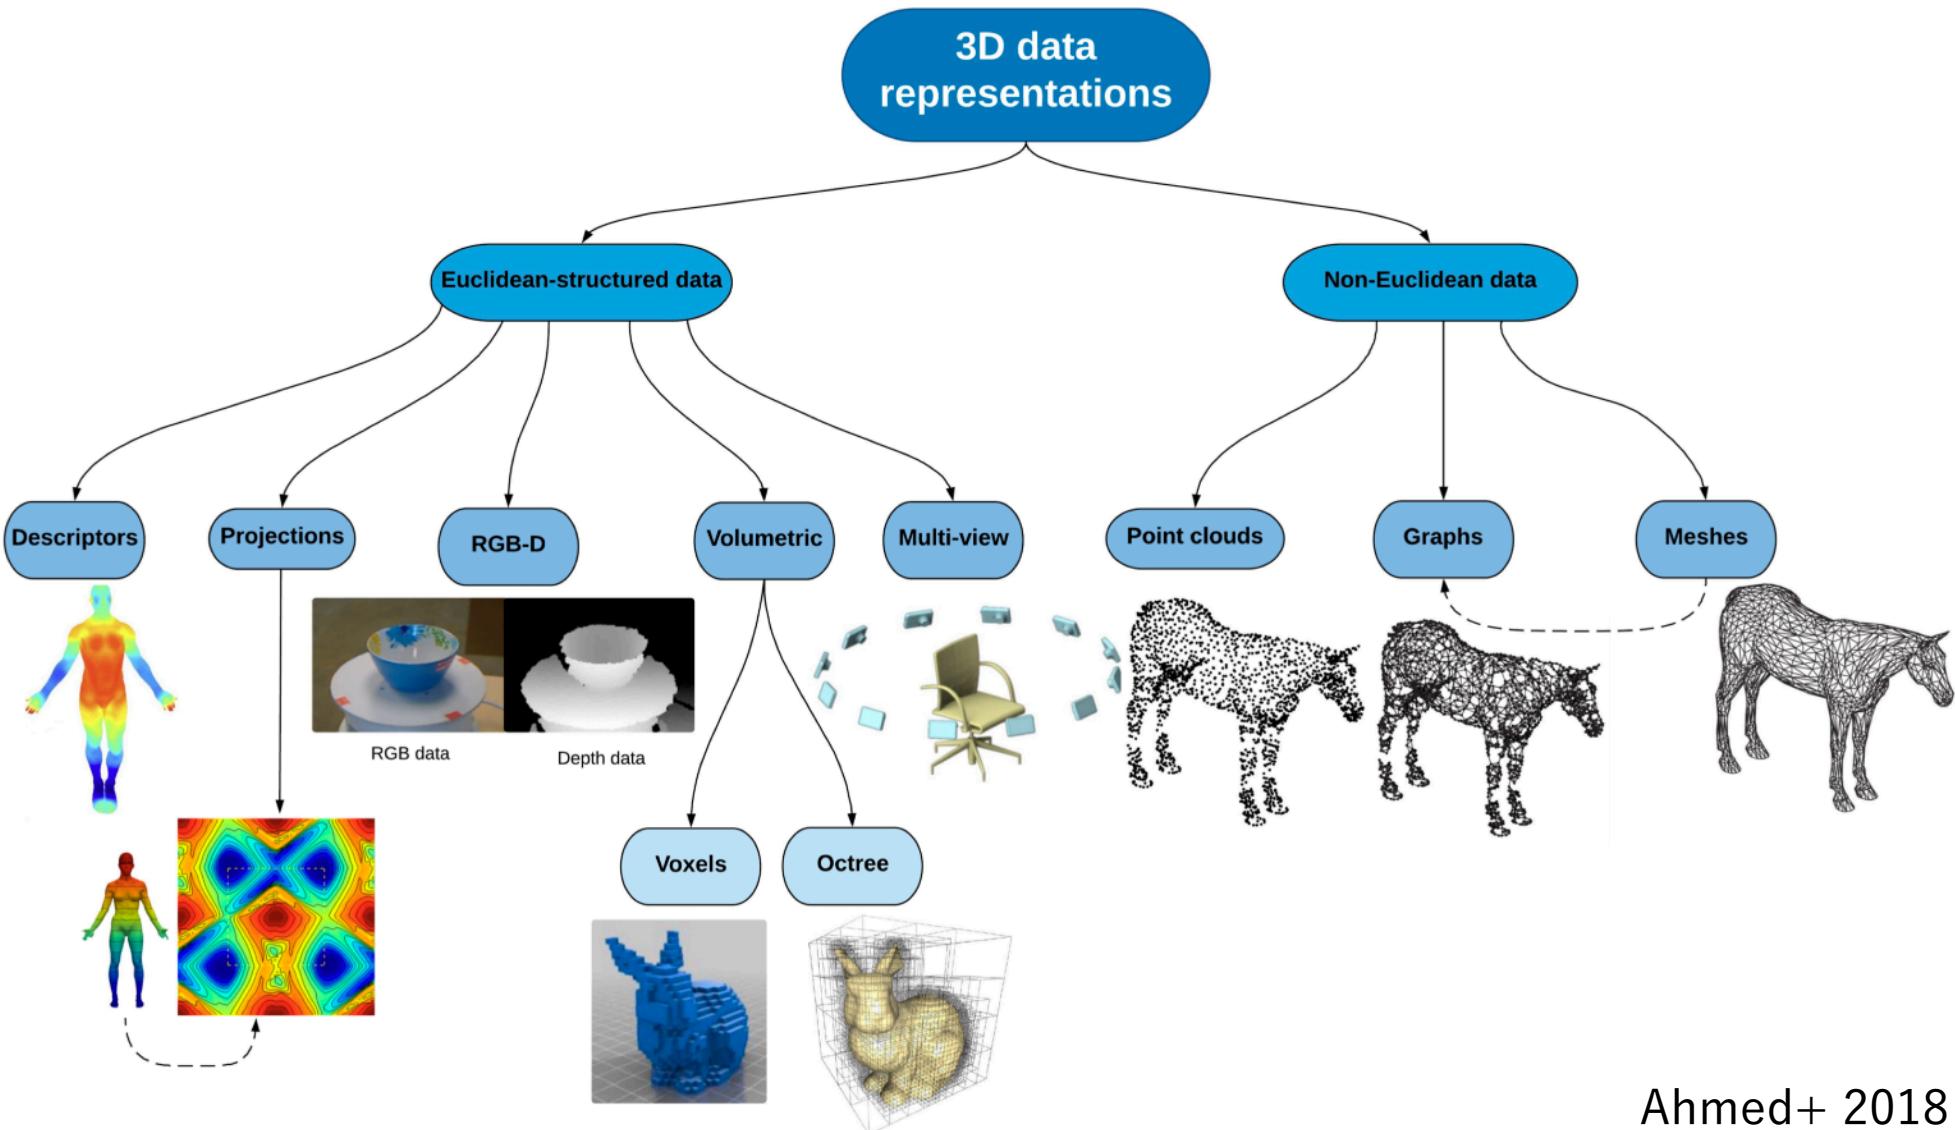
# 目次

- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

# 目次

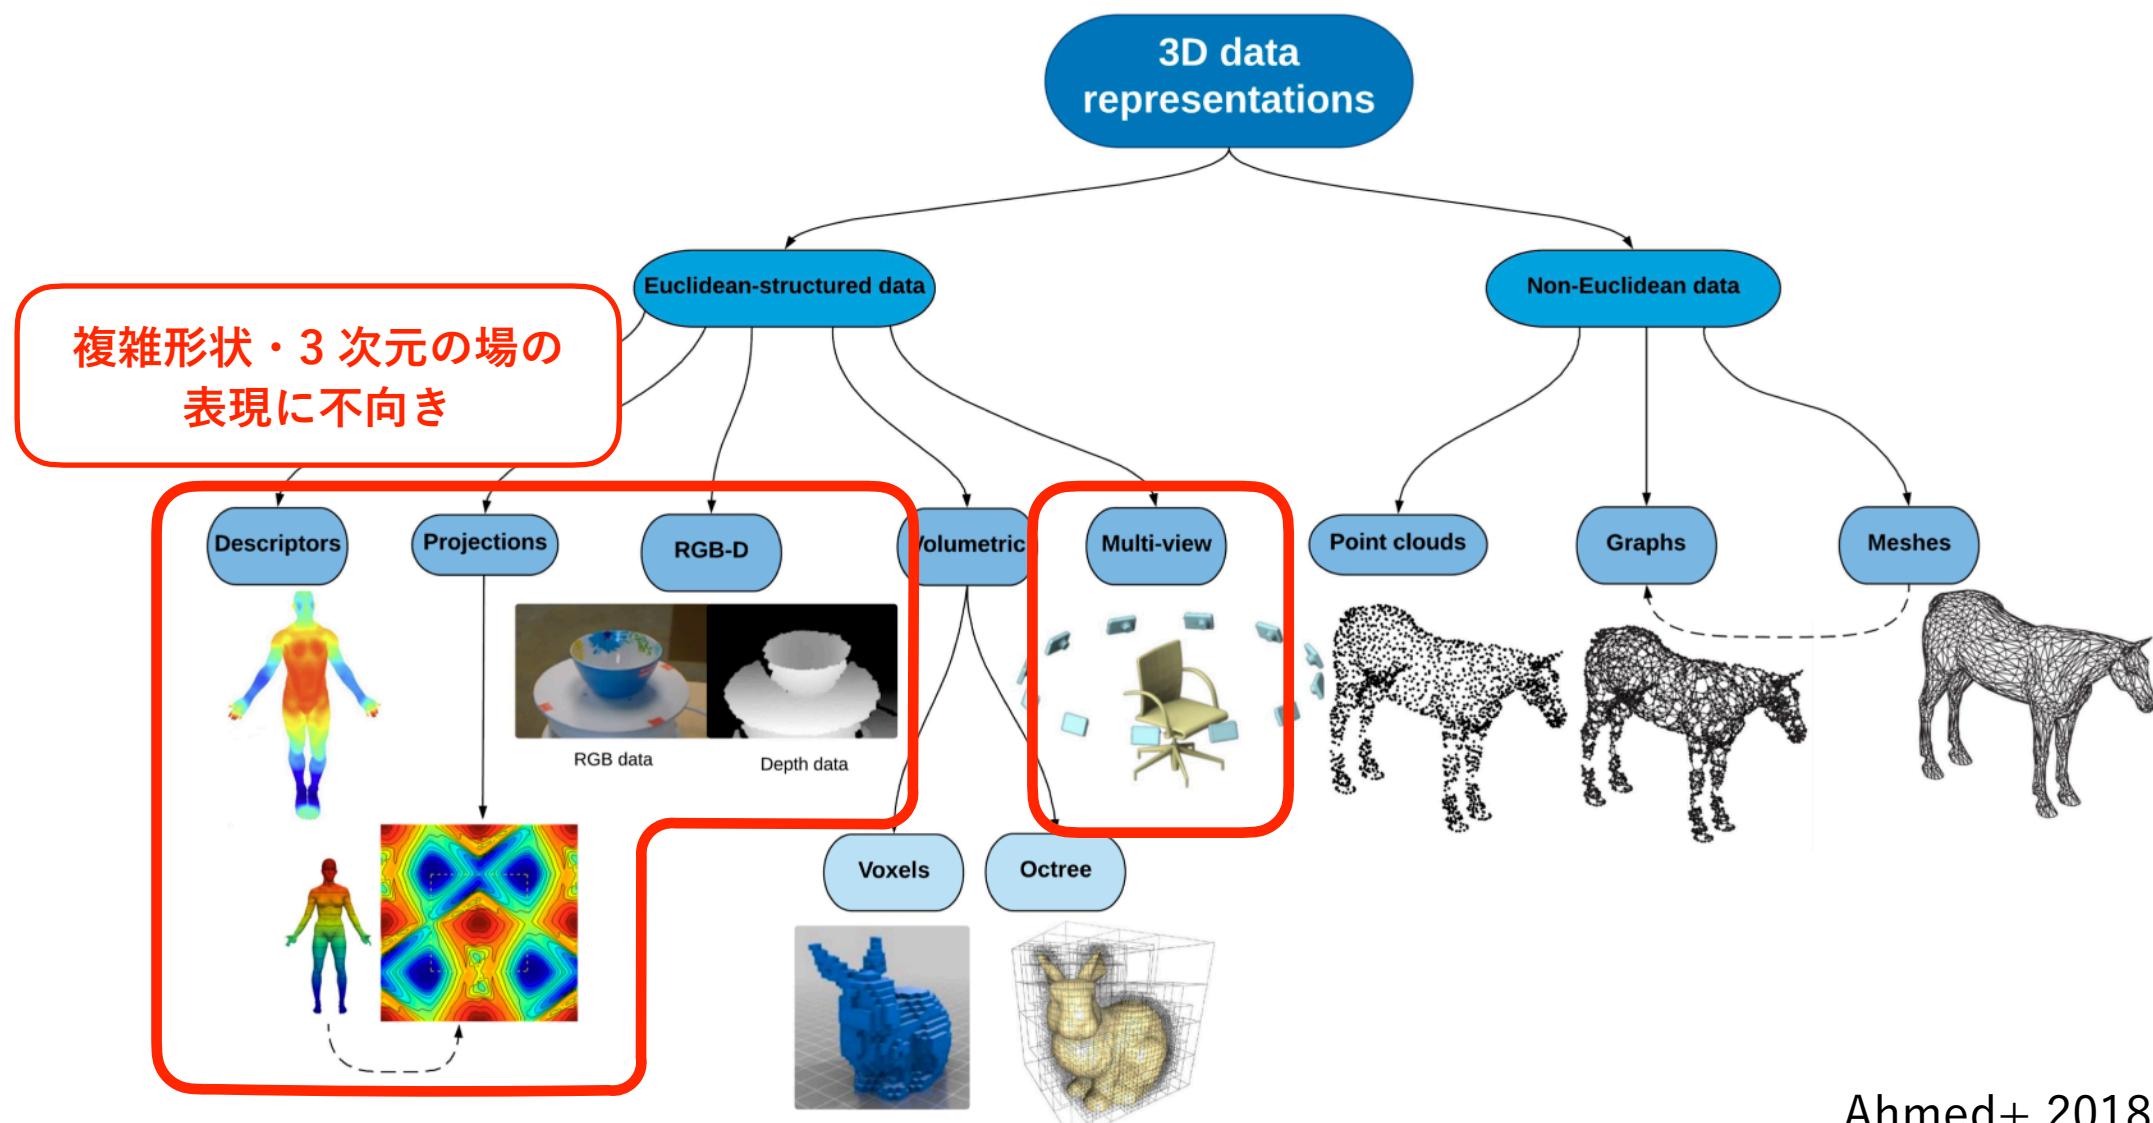
- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

# 3D データをどう扱うか？

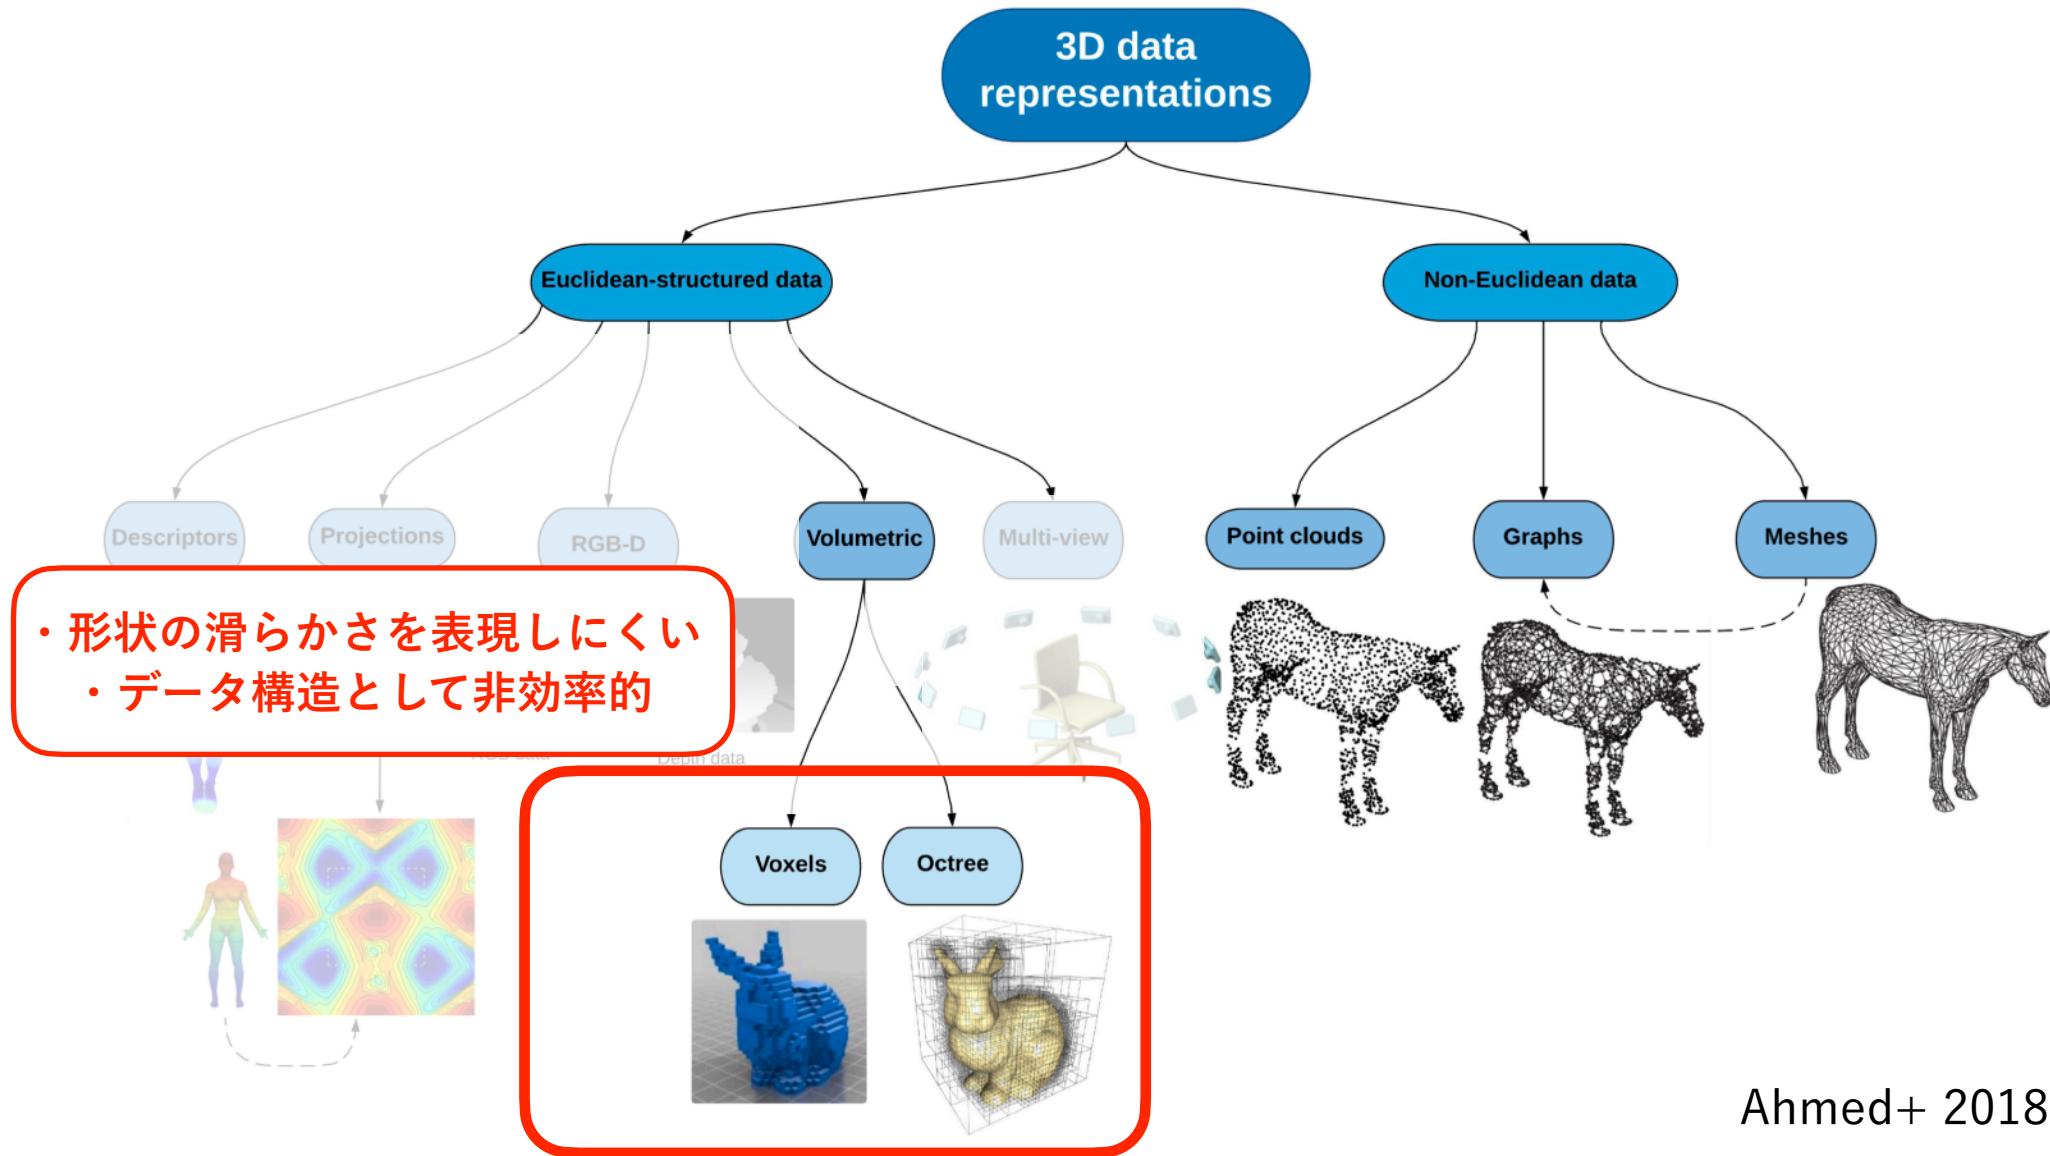


Ahmed+ 2018

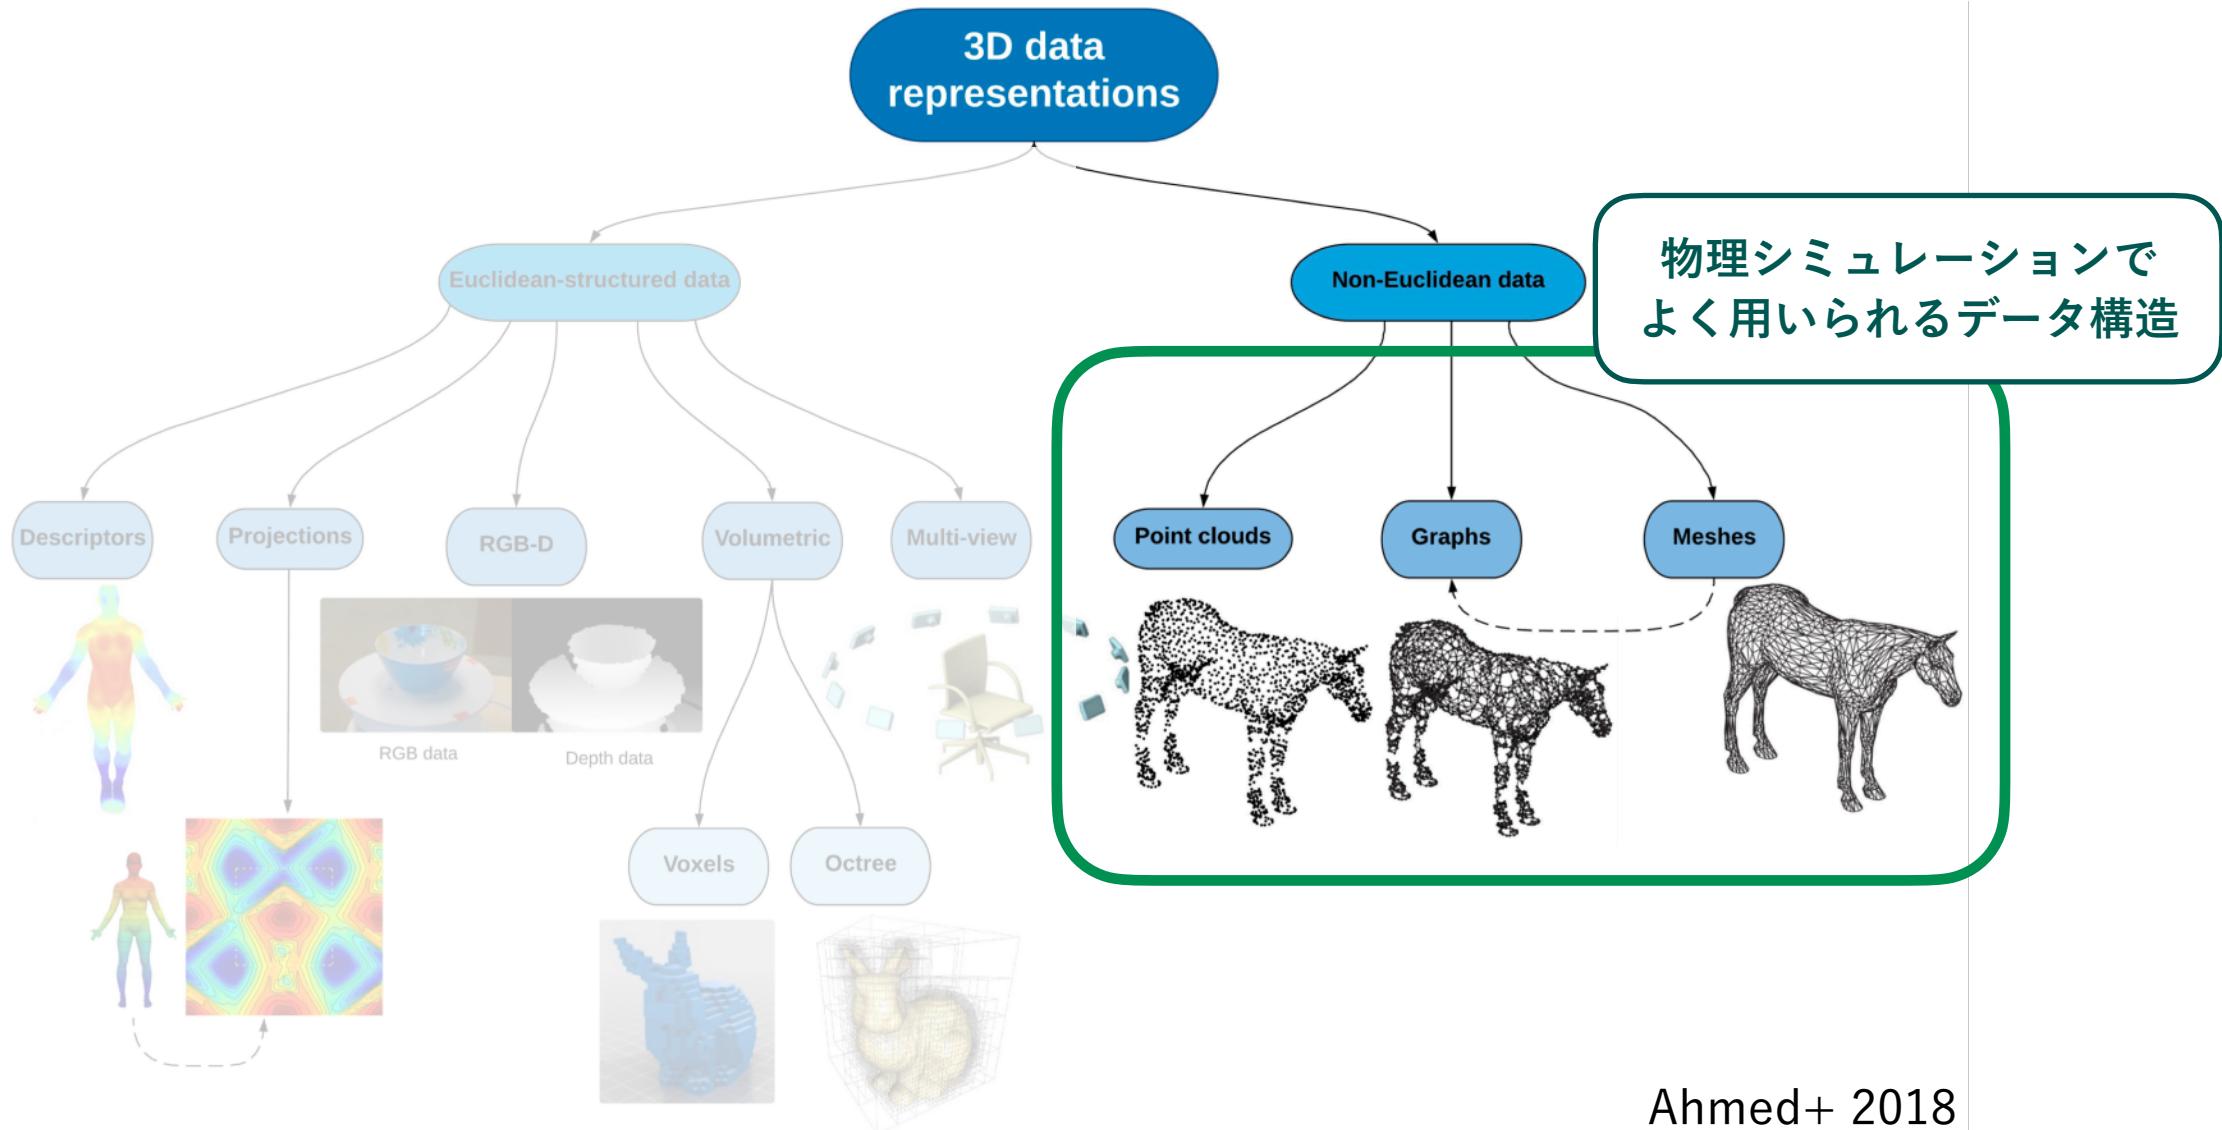
# 3D データをどう扱うか？



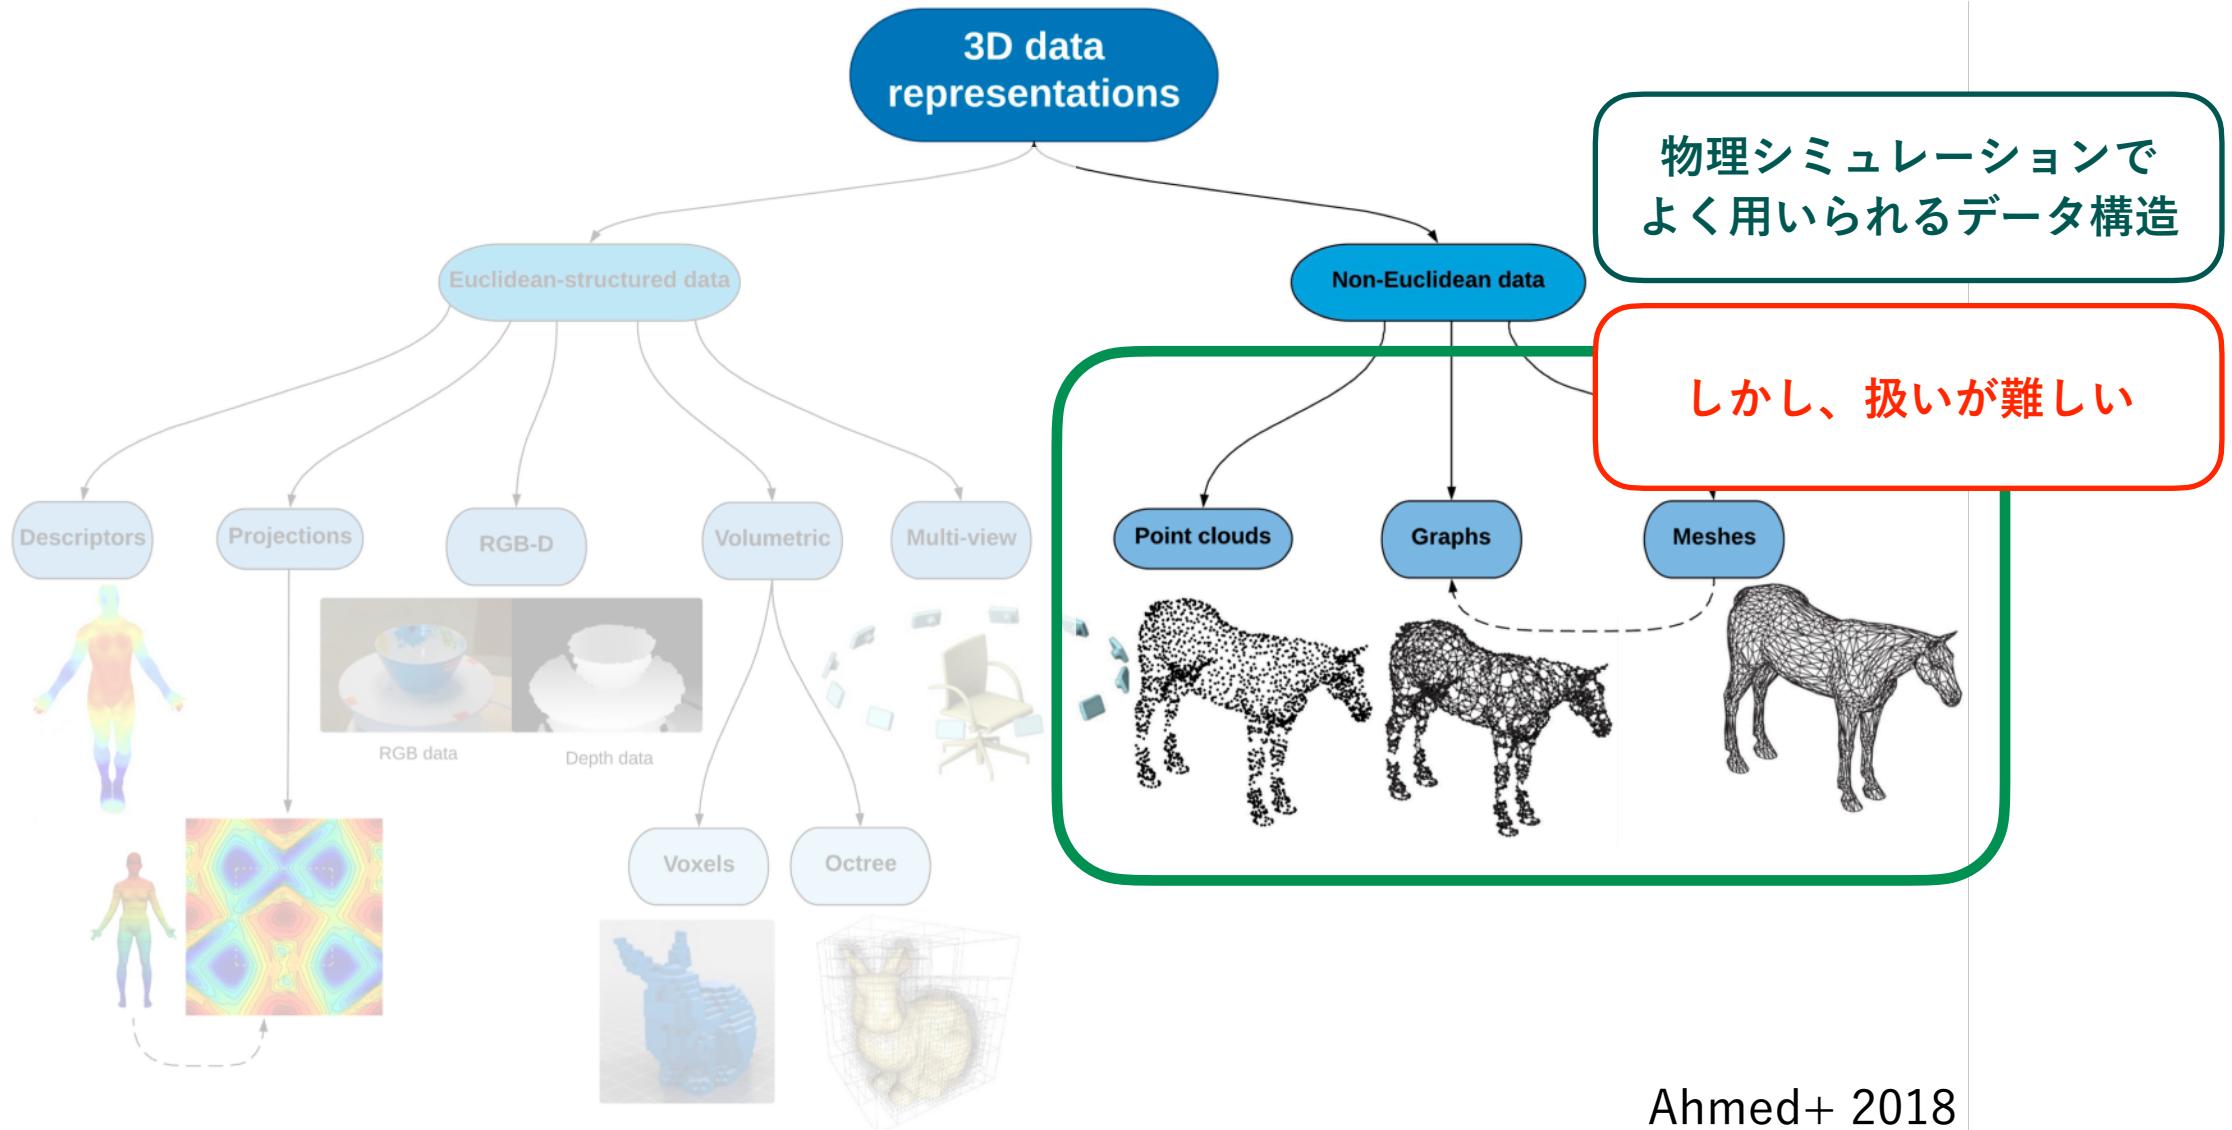
# 3D データをどう扱うか？



# 3D データをどう扱うか？

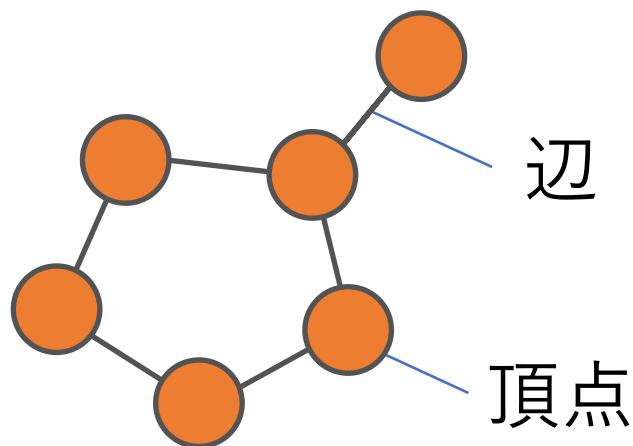


# 3D データをどう扱うか？



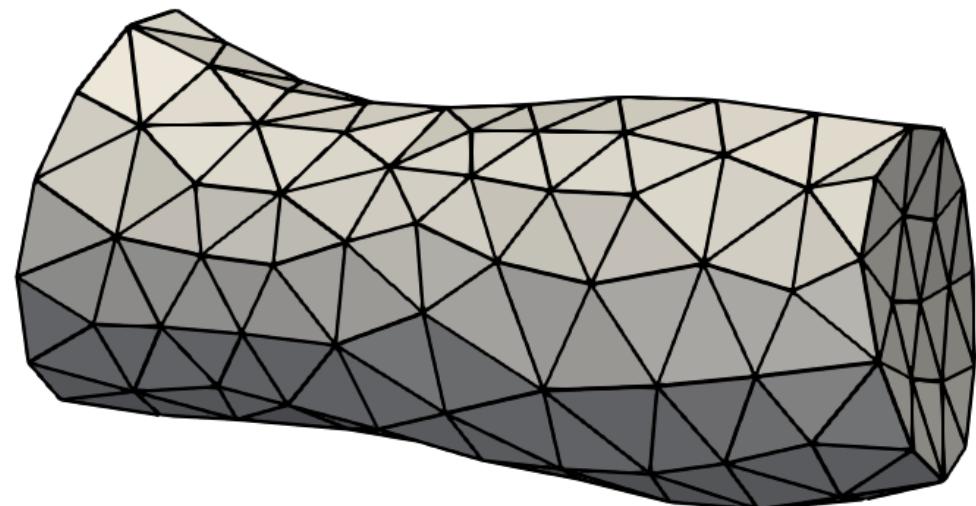
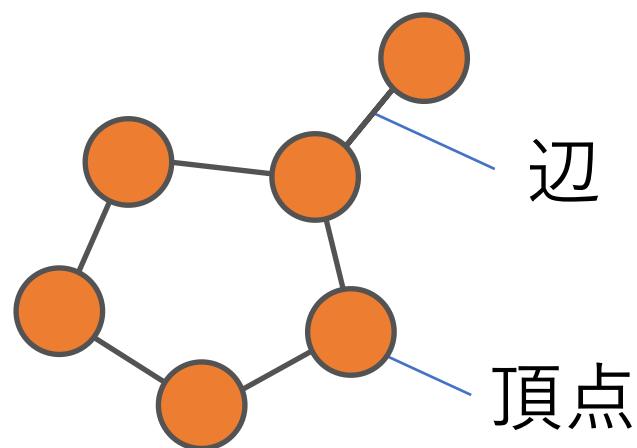
# グラフの難しさ

- ・グラフ：頂点（vertex）と辺（edge）からなるデータ構造



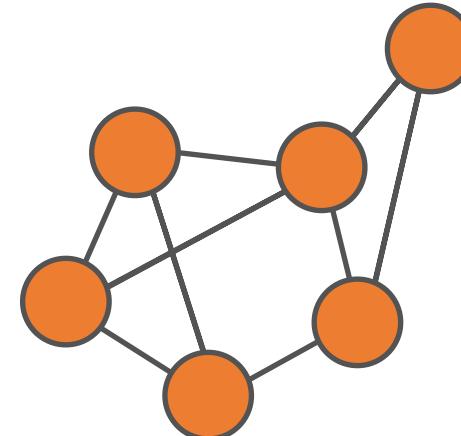
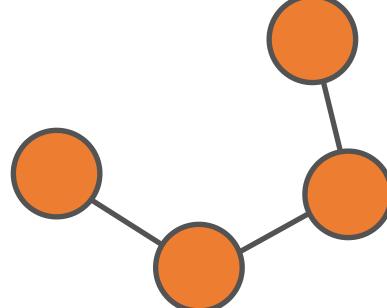
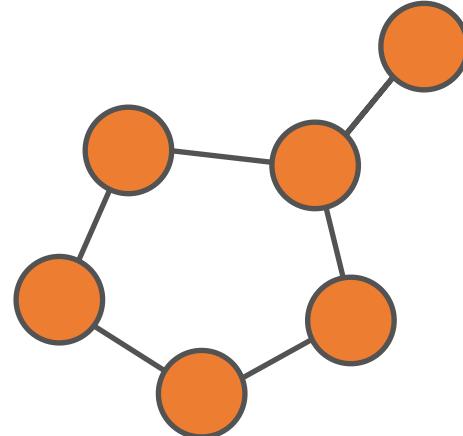
# グラフの難しさ

- ・グラフ：頂点（vertex）と辺（edge）からなるデータ構造
  - メッシュもグラフとみなせる



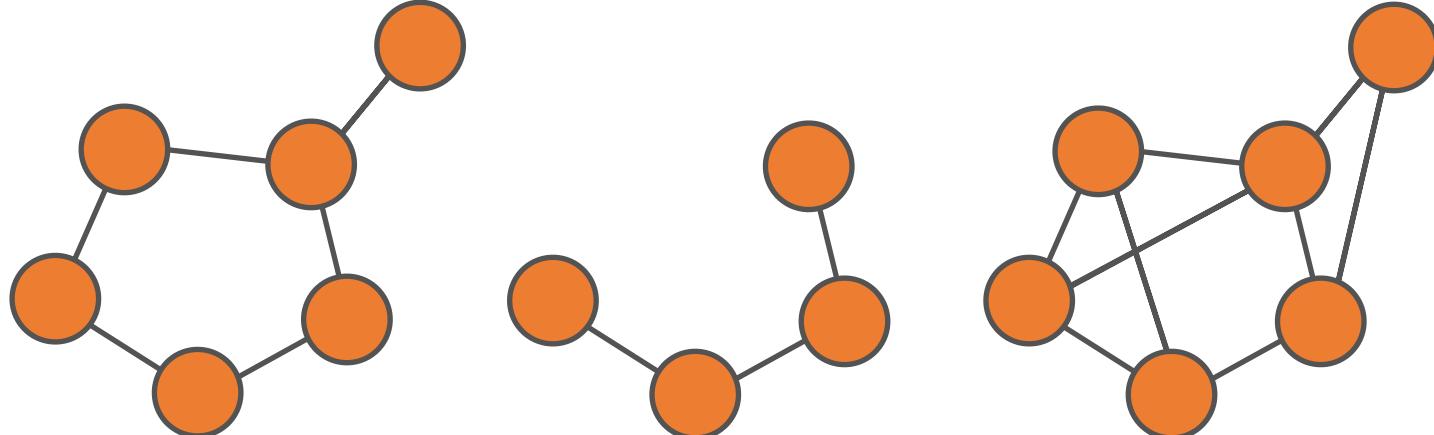
# グラフの難しさ

- ・ グラフ：頂点（vertex）と辺（edge）からなるデータ構造
  - メッシュもグラフとみなせる
- ・ グラフの難しいところ：
  - 頂点の数が不定
  - 頂点から伸びているエッジの数が不定

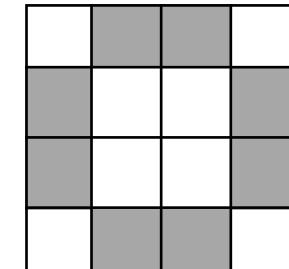


# グラフの難しさ

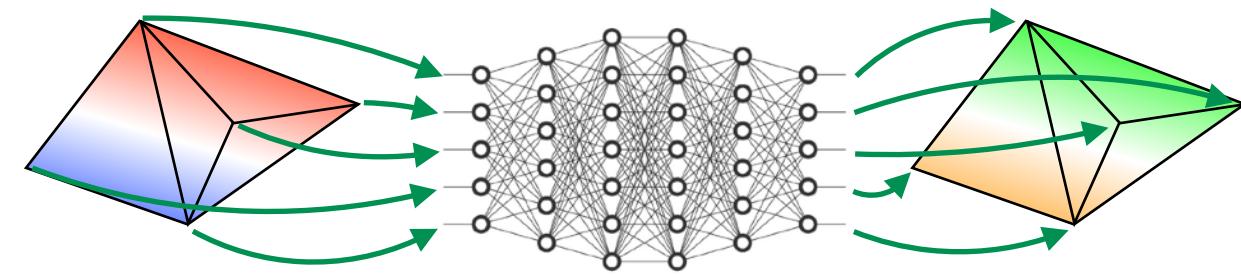
- ・ グラフ：頂点（vertex）と辺（edge）からなるデータ構造
  - メッシュもグラフとみなせる
- ・ グラフの難しいところ：
  - 頂点の数が不定
  - 頂点から伸びているエッジの数が不定



より扱いやすい例：  
画像（格子グラフ）



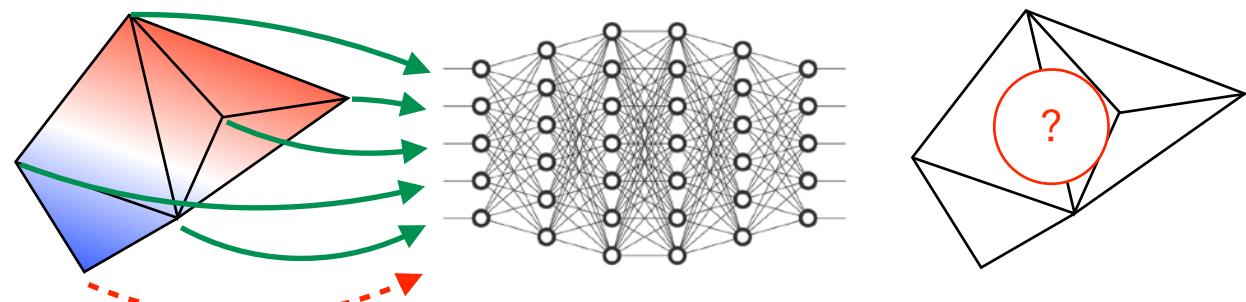
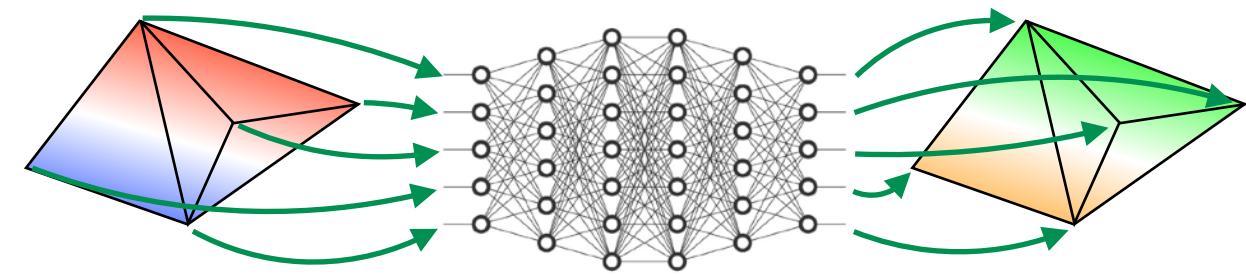
# 全結合ネットワークと Graph Neural Network



全結合ニューラルネットワーク

- 全結合のネットワークではグラフが変わると対応できない

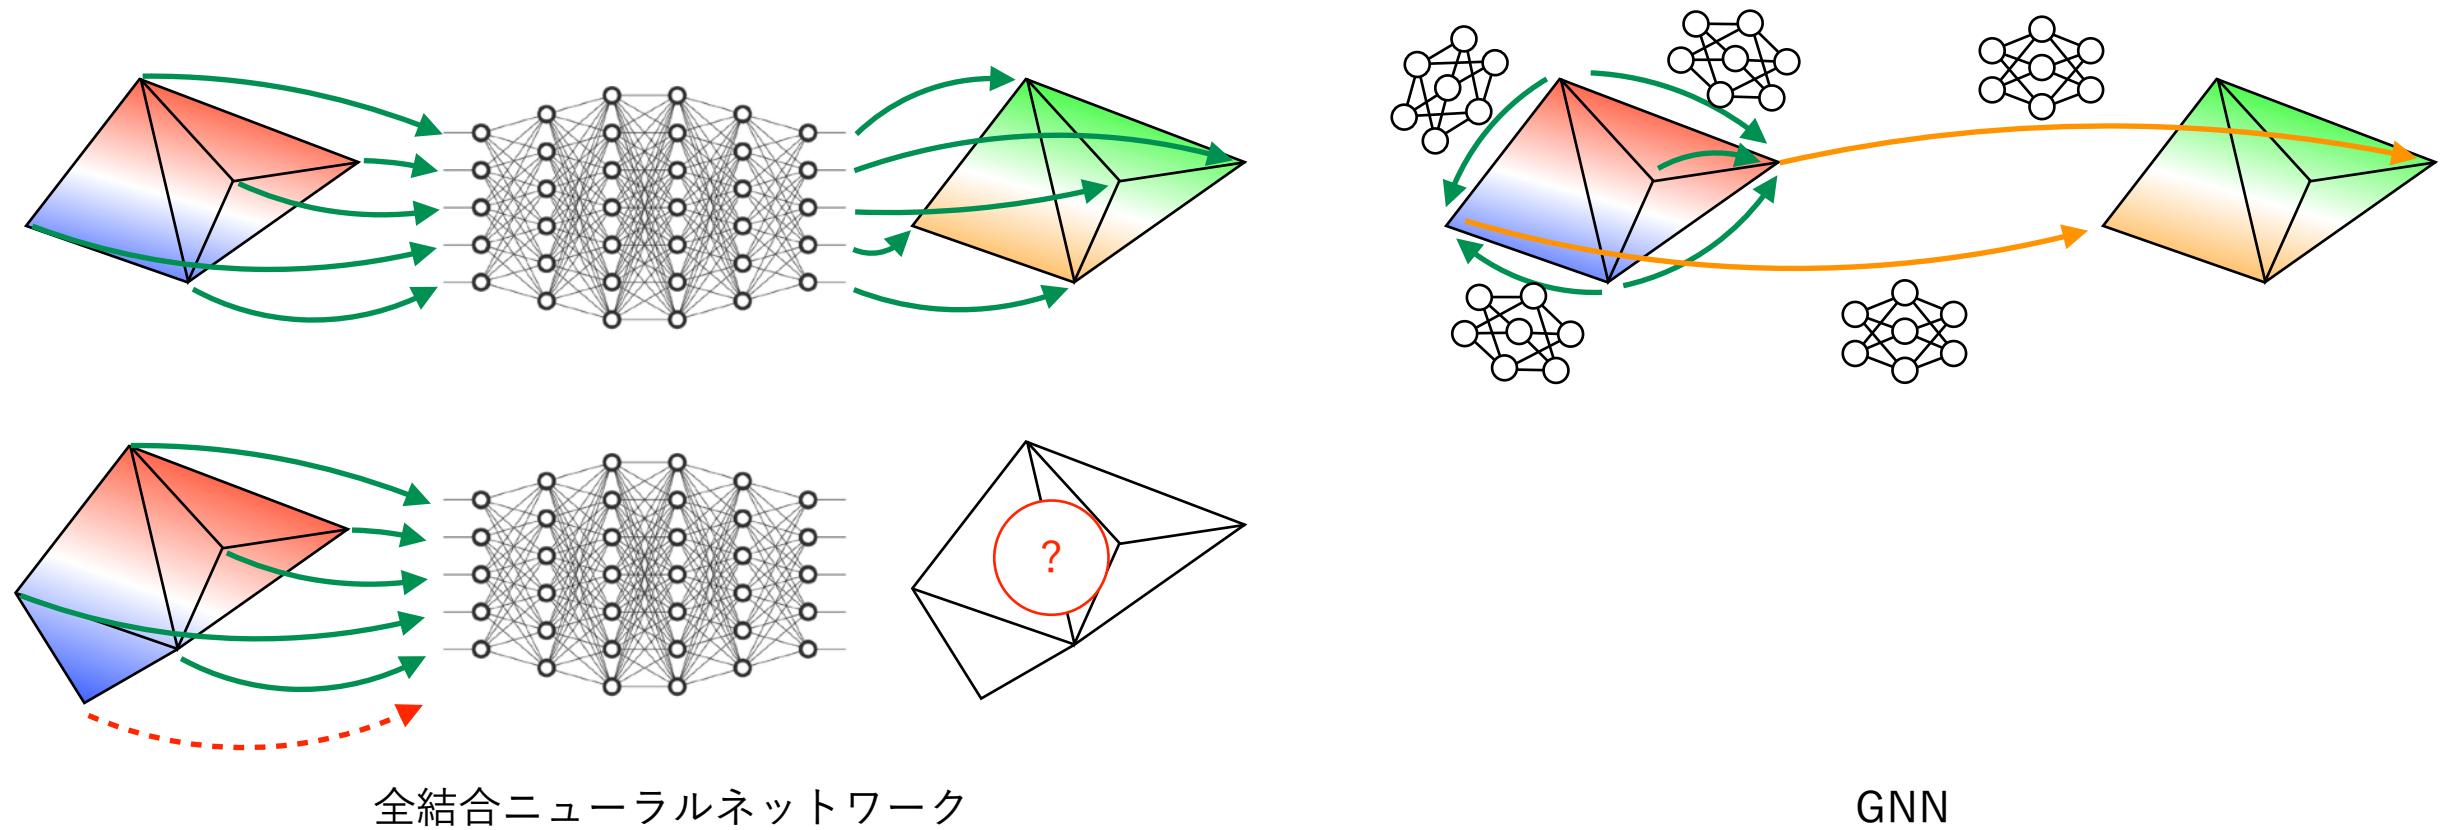
# 全結合ネットワークと Graph Neural Network



全結合ニューラルネットワーク

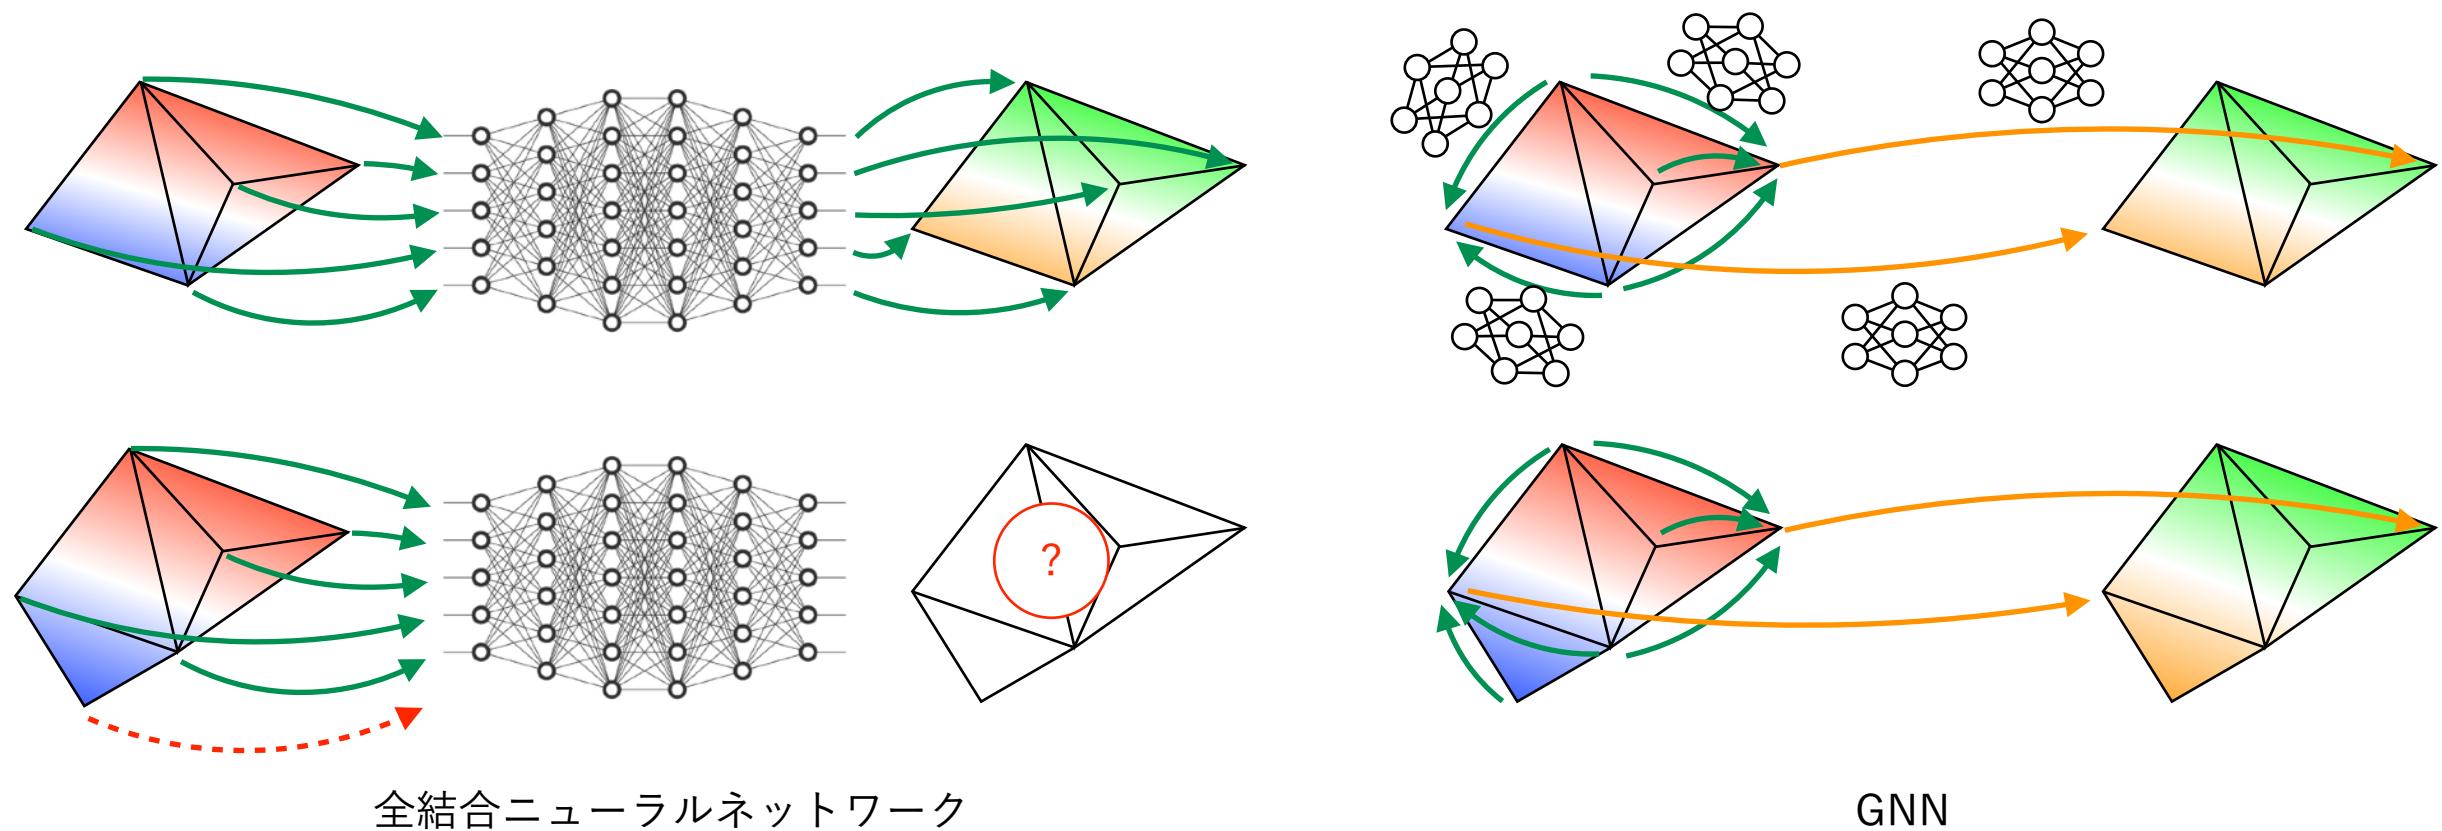
- ・全結合のネットワークではグラフが変わると対応できない

# 全結合ネットワークと Graph Neural Network



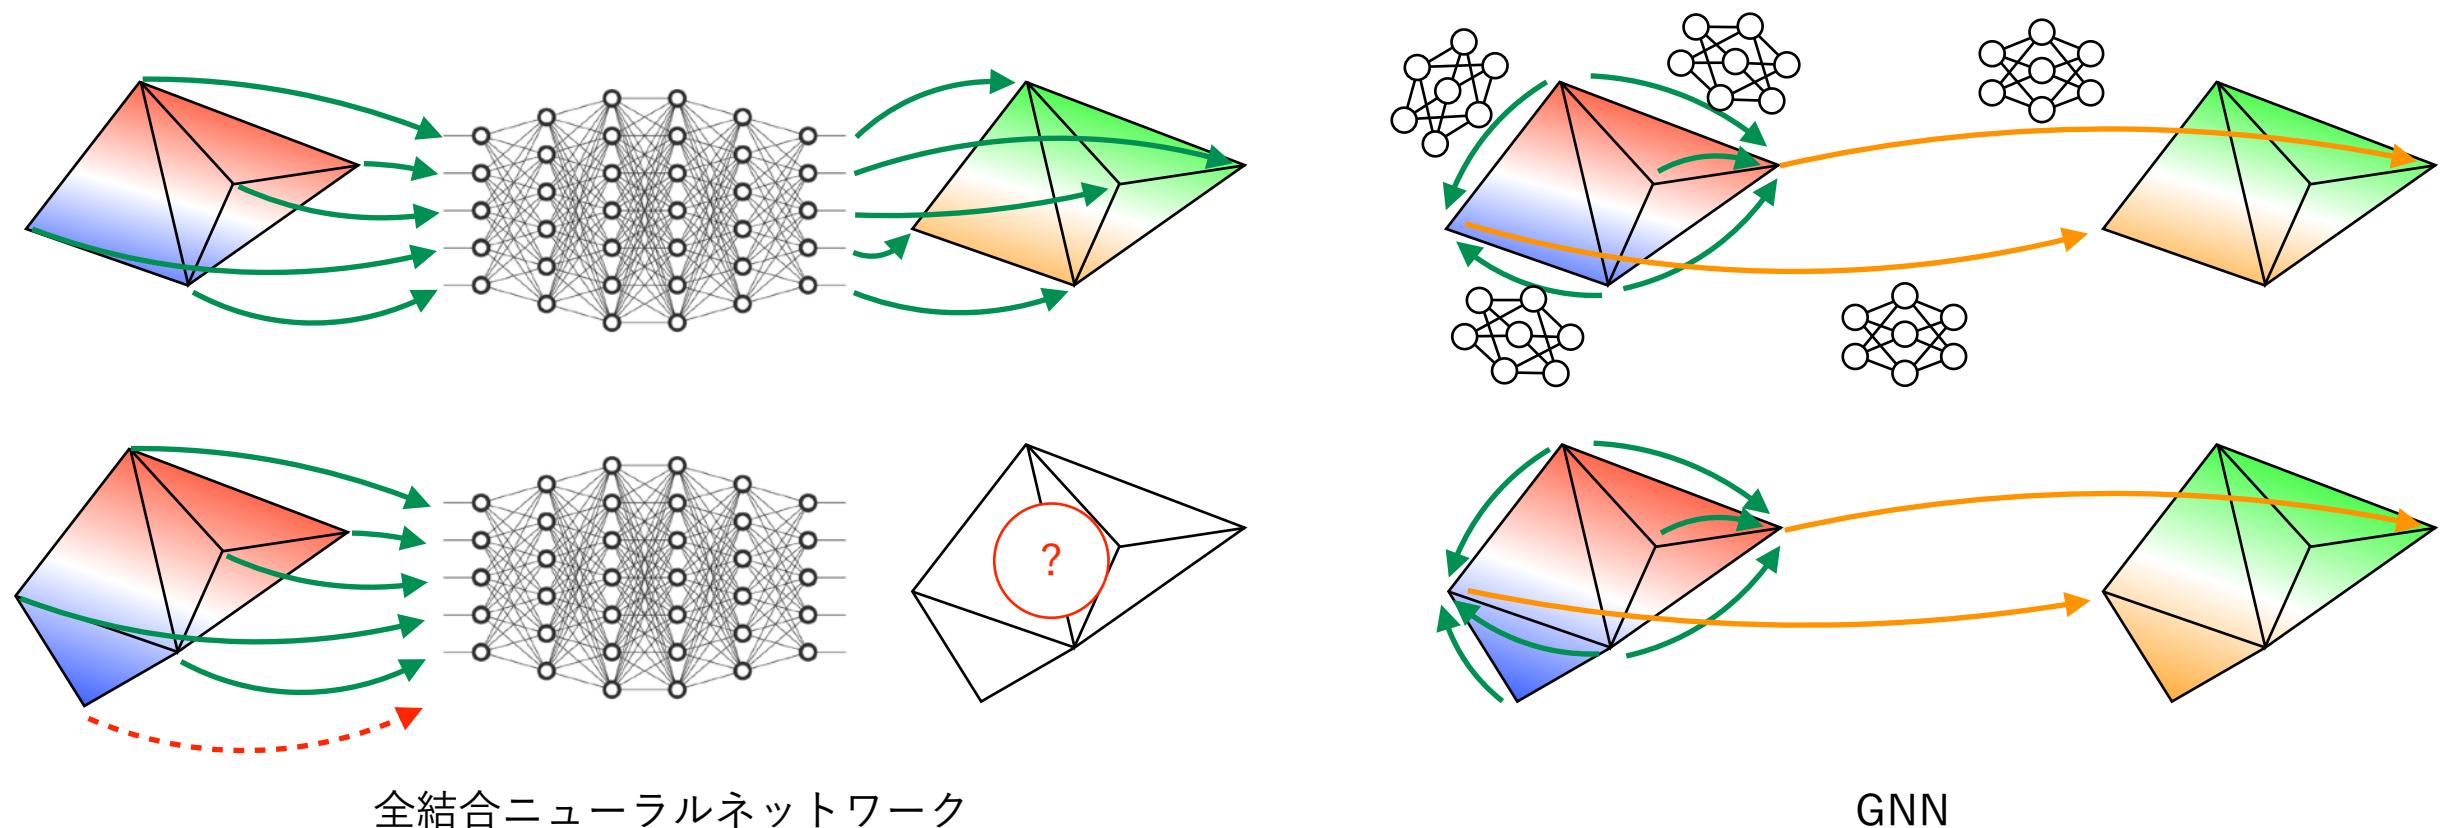
- 全結合のネットワークではグラフが変わると対応できない
- Graph Neural Network (GNN) はグラフの構造が変わっても同じモデルが使える

# 全結合ネットワークと Graph Neural Network



- 全結合のネットワークではグラフが変わると対応できない
- Graph Neural Network (GNN) はグラフの構造が変わっても同じモデルが使える

# 全結合ネットワークと Graph Neural Network



- 全結合のネットワークではグラフが変わると対応できない
- Graph Neural Network (GNN) はグラフの構造が変わっても同じモデルが使える
- 一般的の GNN は計算が重く、大きいグラフ ( $\sim 1M$  節点) に使用できない

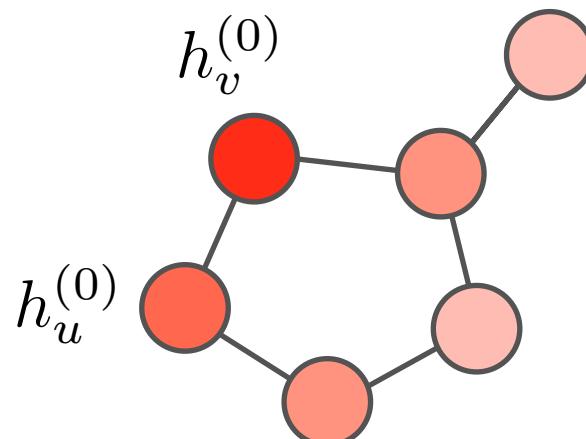
# GCN: 軽量な GNN

- GCN: Graph Convolutional Network (Kipf+ 2017)

- ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$



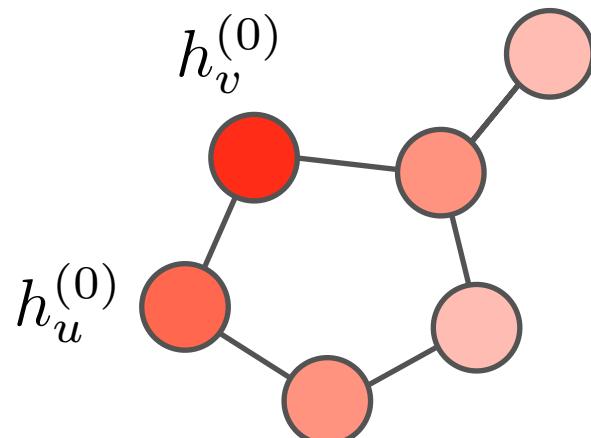
# GCN: 軽量な GNN

- GCN: Graph Convolutional Network (Kipf+ 2017)

- ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$



$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

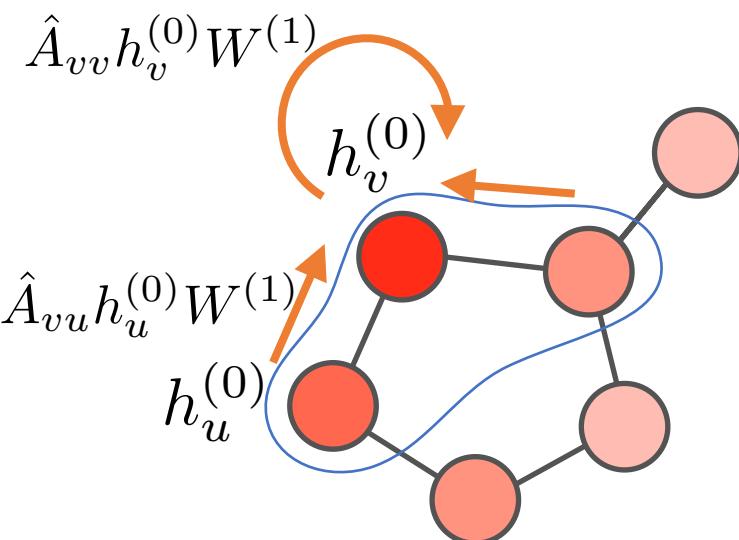
成分ごとに作用する非線形関数

# GCN: 軽量な GNN

- GCN: Graph Convolutional Network (Kipf+ 2017)
  - ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$



$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

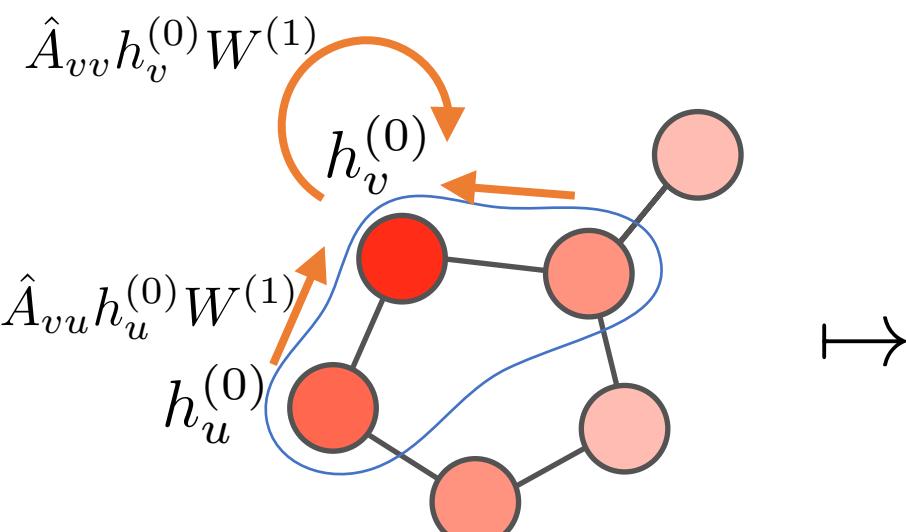
成分ごとに作用する非線形関数

# GCN: 軽量な GNN

- GCN: Graph Convolutional Network (Kipf+ 2017)
  - ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$



$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

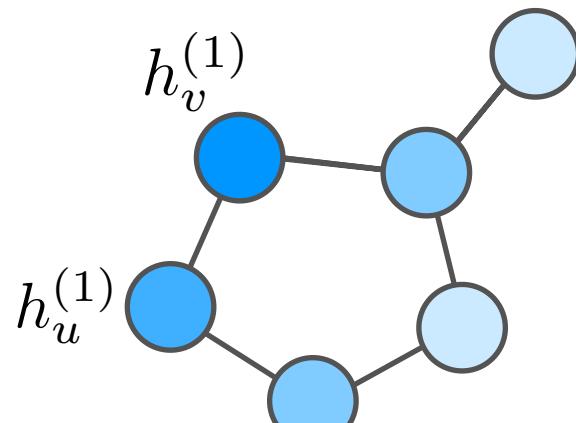
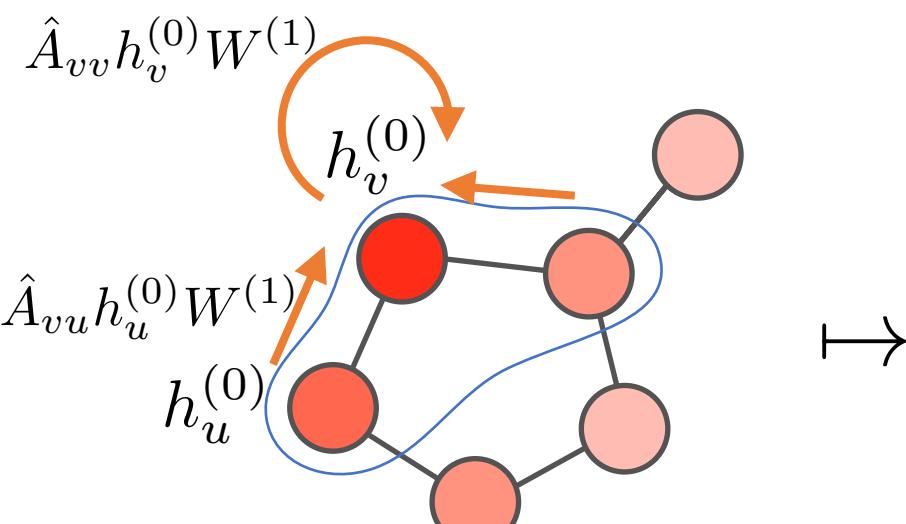
成分ごとに作用する非線形関数

# GCN: 軽量な GNN

- GCN: Graph Convolutional Network (Kipf+ 2017)
  - ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$



$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

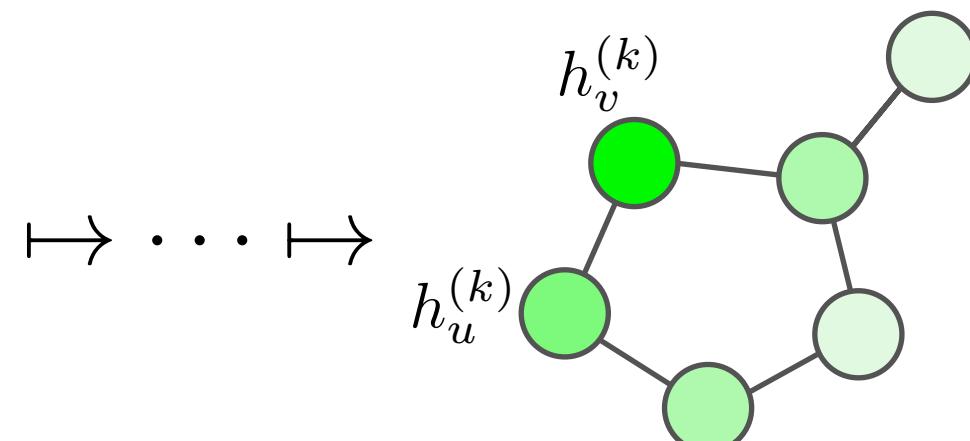
$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

成分ごとに作用する非線形関数



# 目次

- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

# 目次

- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

# 不变性と同変性：現象の持つ対称性

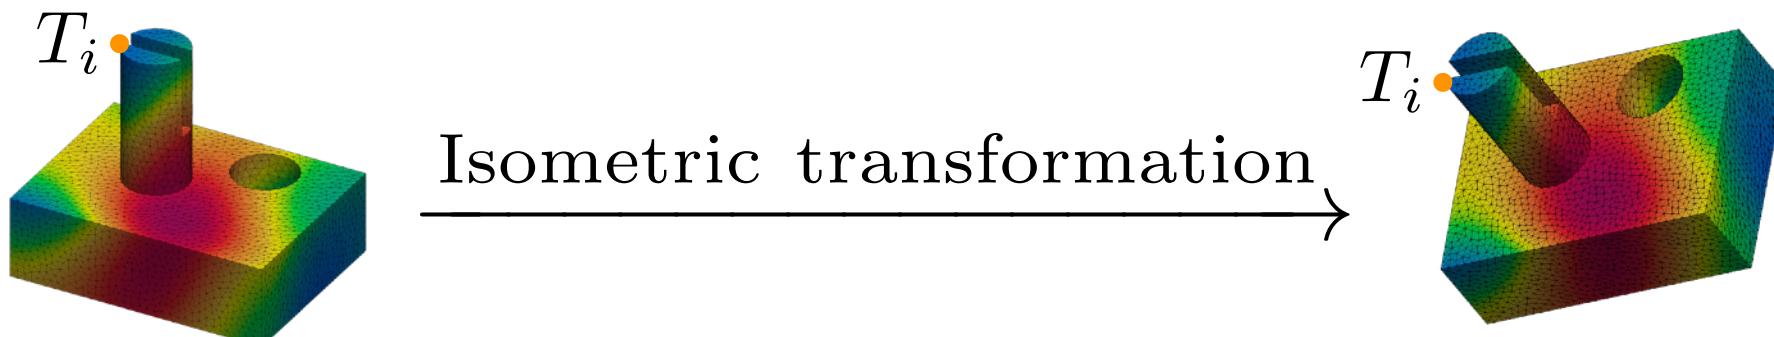
$G$  を群、 $X$ 、 $Y$  を左  $G$ -集合とする

- 関数  $f: X \rightarrow Y$  が群  $G$  の作用に対して不変 (invariant) である：

$$\forall g \in G, \forall x \in X, f(g \cdot x) = f(x)$$

$$\begin{array}{ccc} X & \xrightarrow{g \cdot} & X \\ & f \searrow & \downarrow f \\ & & Y \end{array}$$

- 例：温度は合同変換（回転・鏡映・平行移動）に対して不変



# 不变性と同変性：現象の持つ対称性

$G$  を群、 $X$ 、 $Y$  を左  $G$ -集合とする

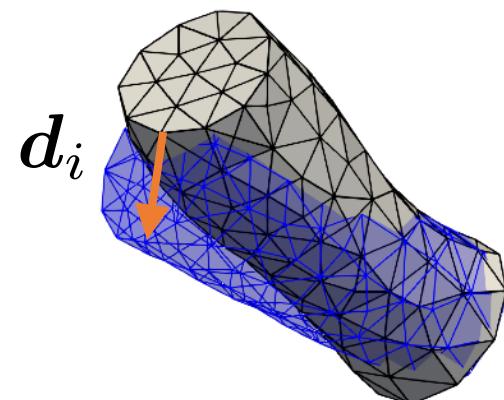
- 関数  $f: X \rightarrow Y$  が群  $G$  の作用に対して **同変** (equivariant) である：

$$\forall g \in G, \forall x \in X, f(g \cdot x) = g \cdot f(x)$$

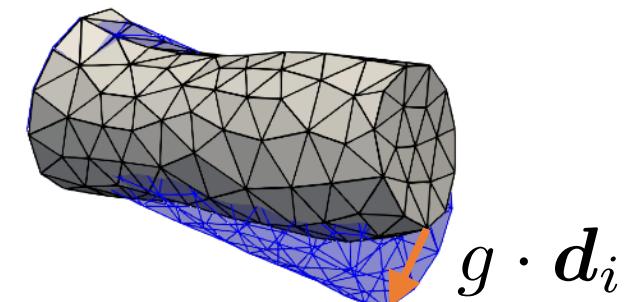
- 例：変位は直交変換（回転・鏡映）に対して同変

- 変位は平行移動に対して不変

- 不変性は同変性の一種なので、変位は合同変換に対して同変



Orthogonal transformation



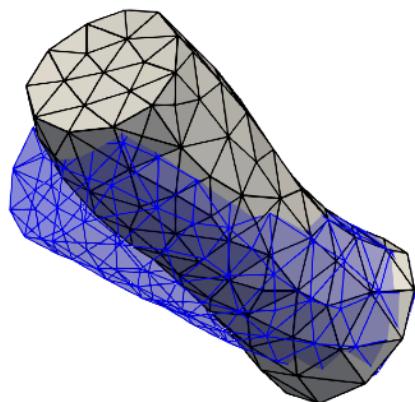
$$\begin{array}{ccc} X & \xrightarrow{g \cdot} & X \\ \downarrow f & & \downarrow f \\ Y & \xrightarrow{g \cdot} & Y \end{array}$$

# 不变性と同変性：現象の持つ対称性

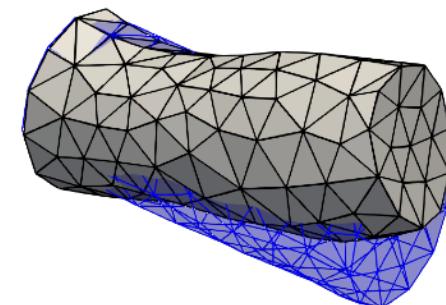
合同変換の群（ユークリッド群）を  $E(n)$  とする

- 物理量・物理法則は合同変換同変である
  - 例：フックの法則

$$\forall e \in E(n), \sigma = -C\varepsilon \Rightarrow e \cdot \sigma = -(e \cdot C)(e \cdot \varepsilon)$$



Orthogonal transformation 



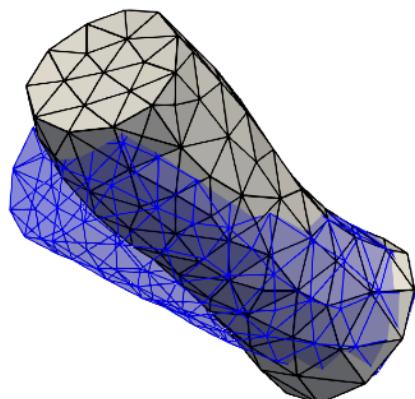
# 不变性と同変性：現象の持つ対称性

合同変換の群（ユークリッド群）を  $E(n)$  とする

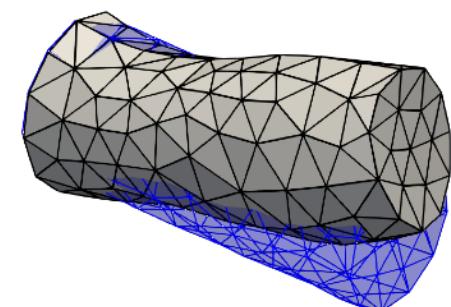
- 物理量・物理法則は合同変換同変である
  - 例：フックの法則

$$\forall e \in E(n), \sigma = -C\varepsilon \Rightarrow e \cdot \sigma = -(e \cdot C)(e \cdot \varepsilon)$$

$$\begin{aligned} U^e \in O(n), U_{ii'}^e U_{jj'}^e \sigma_{i'j'} &= -U_{ii'}^e U_{jj'}^e U_{kk'}^e U_{ll'}^e C_{i'j'k'l'} U_{kk''}^e U_{ll''}^e \varepsilon_{k''l''} \\ &= -U_{ii'}^e U_{jj'}^e \delta_{k'k''} \delta_{l'l''} C_{i'j'k'l'} \varepsilon_{k''l''} \\ &= -U_{ii'}^e U_{jj'}^e C_{i'j'k'l'} \varepsilon_{k'l'} \end{aligned}$$



Orthogonal transformation



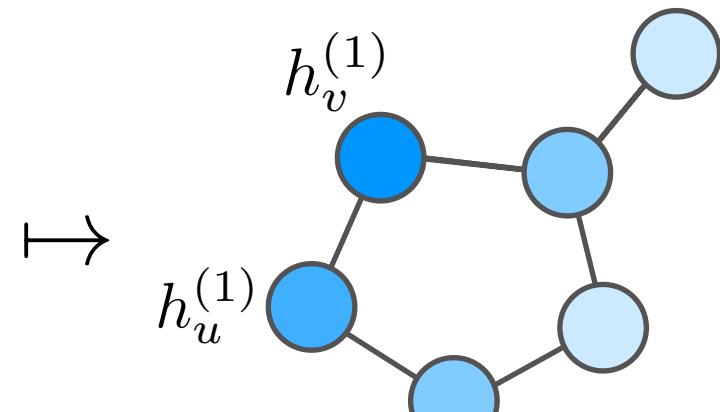
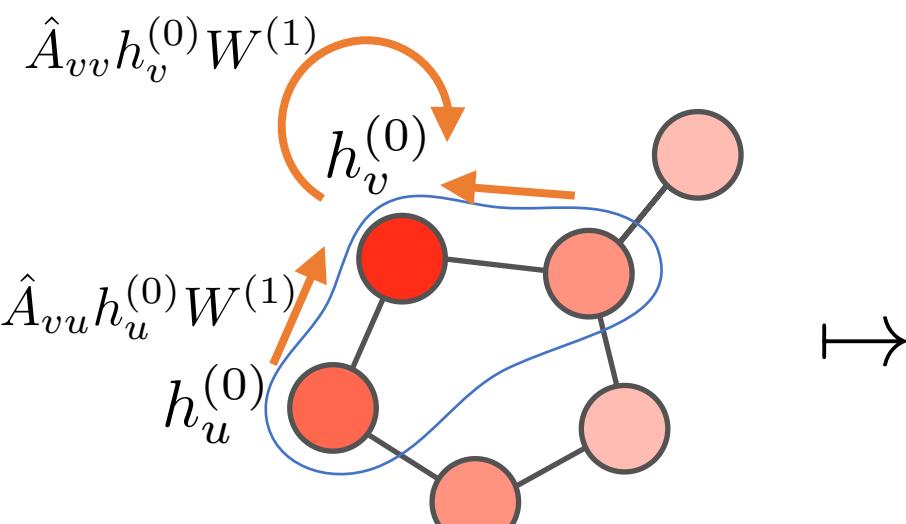
# GCN と不变性・同変性

- GCN: Graph Convolutional Network (Kipf+ 2017)

- ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$



$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

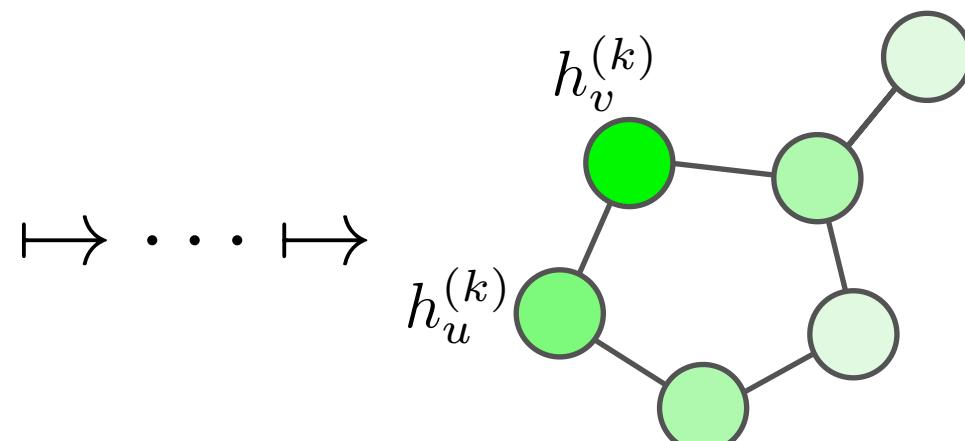
$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

成分ごとに作用する非線形関数



# GCN と不变性・同変性

- GCN: Graph Convolutional Network (Kipf+ 2017)

- ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$

- GCN は、入力が合同変換不変のときのみ不变
- 不变性を保ったままノード位置を入力できない

$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

成分ごとに作用する非線形関数

# GCN と不变性・同変性

- GCN: Graph Convolutional Network (Kipf+ 2017)

- ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$

- GCN は、入力が合同変換不変のときのみ不变

- 不变性を保ったままノード位置を入力できない

$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

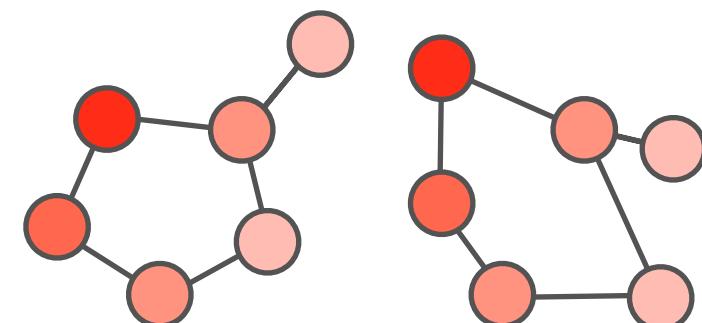
$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

成分ごとに作用する非線形関数



# GCN と不变性・同変性

- GCN: Graph Convolutional Network (Kipf+ 2017)

- ノード間の相互作用を線形化しモデルを軽量化

$$\hat{A} = \tilde{D}^{-\frac{1}{2}}(A + I)\tilde{D}^{-\frac{1}{2}}$$

$$h_v^{(k)} = \text{Activation}^{(k)} \left( \sum_u \hat{A}_{vu} h_u^{(k-1)} W^{(k)} \right)$$

- GCN は、入力が合同変換不変のときのみ不变

- 不変性を保ったままノード位置を入力できない

- 一般に GCN は合同変換同変とならない

$$\exists e \in E(d), e \cdot h^{(k)} \neq \text{Activation}^{(k)}(\hat{A}e \cdot h^{(k-1)} W^{(k)})$$

$|\mathcal{V}|$ : グラフのノード数

$A \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ : 隣接行列

$\tilde{D}$ :  $A + I$  の度数行列

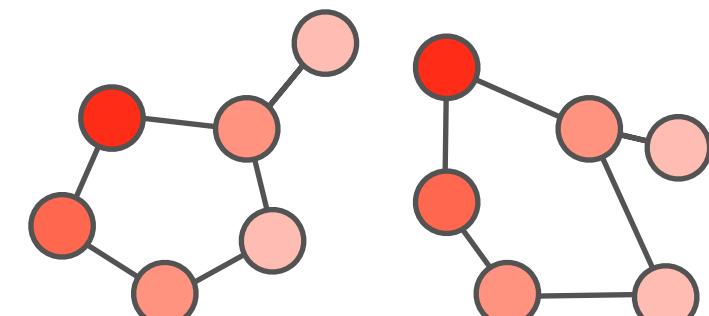
$h^{(k)} \in \mathbb{R}^{|\mathcal{V}| \times f^{(k)}}$ : 特徴量行列

$W^{(k)} \in \mathbb{R}^{f^{(k-1)} \times f^{(k)}}$ :

学習するパラメータ行列

$\text{Activation}^{(k)}$ :

成分ごとに作用する非線形関数



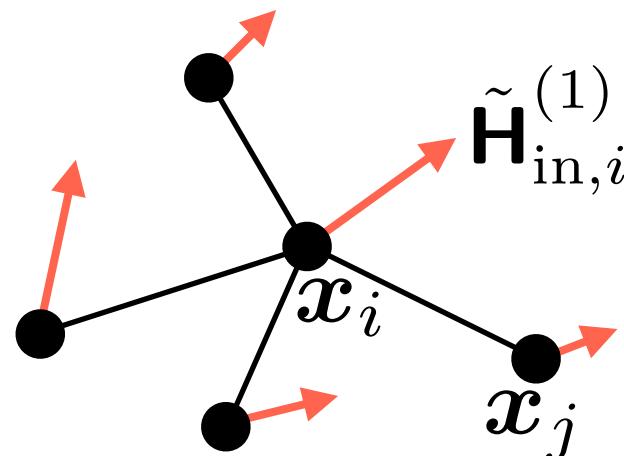
# Tensor field network: 合同変換同変な機械学習モデル

- TFN: Tensor field network (Thomas+ 2018)

- 球面調和関数を用いた  
合同変換不变・同変な機械学習モデル

$$\tilde{\mathbf{H}}_{\text{out},i}^{(l)} = w^{ll} \tilde{\mathbf{H}}_{\text{in},i}^{(l)} + \sum_{k \geq 0} \sum_{j \neq i} \mathbf{W}^{lk}(\mathbf{x}_j - \mathbf{x}_i) \tilde{\mathbf{H}}_{\text{in},j}^{(k)}$$

$$\mathbf{W}^{lk}(\mathbf{x}) = \sum_{J=|k-l|}^{k+l} \phi_J^{lk}(\|\mathbf{x}\|) \sum_{m=-J}^J Y_{Jm}(\mathbf{x}/\|\mathbf{x}\|) \mathbf{Q}_{Jm}^{lk}$$

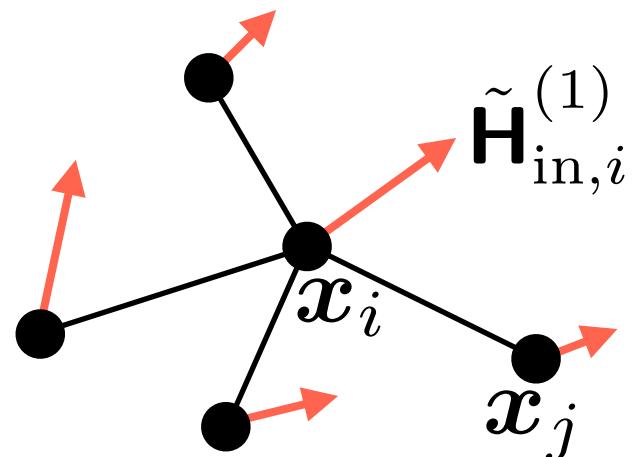


# Tensor field network: 合同変換同変な機械学習モデル

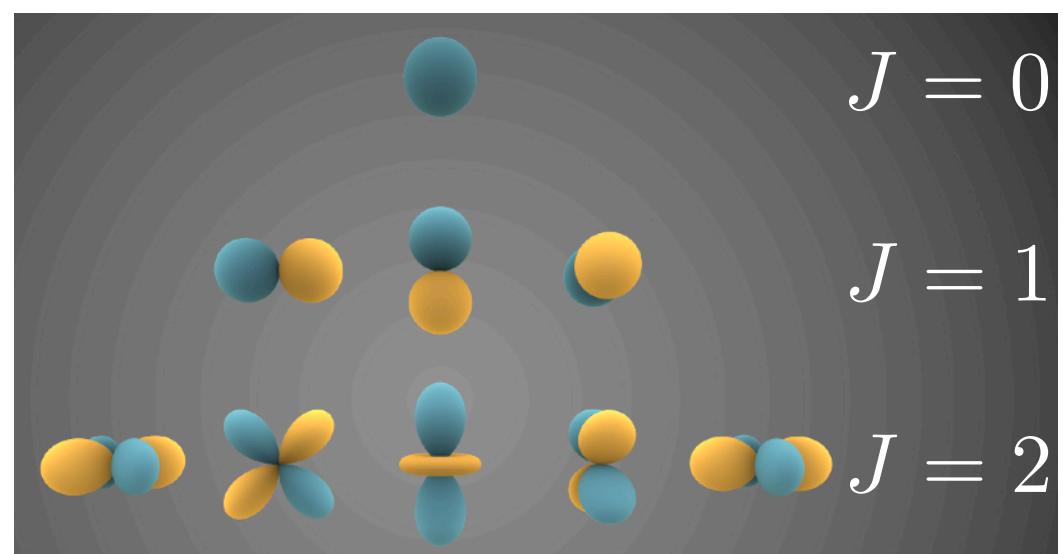
- TFN: Tensor field network (Thomas+ 2018)
  - 球面調和関数を用いた  
合同変換不变・同変な機械学習モデル

$$\tilde{\mathbf{H}}_{\text{out},i}^{(l)} = w^{ll} \tilde{\mathbf{H}}_{\text{in},i}^{(l)} + \sum_{k \geq 0} \sum_{j \neq i} \mathbf{W}^{lk}(\mathbf{x}_j - \mathbf{x}_i) \tilde{\mathbf{H}}_{\text{in},j}^{(k)}$$

$$\mathbf{W}^{lk}(\mathbf{x}) = \sum_{J=|k-l|}^{k+l} \phi_J^{lk}(\|\mathbf{x}\|) \sum_{m=-J}^J Y_{Jm}(\mathbf{x}/\|\mathbf{x}\|) \mathbf{Q}_{Jm}^{lk}$$



$\tilde{\mathbf{H}}_{\text{in},i}^{(l)} \in \mathbb{R}^{2l+1}$  : type- $l$  入力  
 (l階テンソルに対応)  
 $\mathbf{x}_i$  :  $i$  番目ノード位置  
 $w^{ll}$  : 学習するパラメータ  
 $\phi_J^{lk} : \mathbb{R}_{\geq 0} \rightarrow \mathbb{R}$  : 学習する関数  
 $Y_J : \mathbb{R}^3 \rightarrow \mathbb{R}^{2J+1}$  : 球面調和関数



# Tensor field network: 合同変換同変な機械学習モデル

- TFN: Tensor field network (Thomas+ 2018)  
- 球面調和関数を用いた  
合同変換不变・同変な機械学習モデル

$$\tilde{\mathbf{H}}_{\text{out},i}^{(l)} = w^{ll} \tilde{\mathbf{H}}_{\text{in},i}^{(l)} + \sum_{k \geq 0} \sum_{j \neq i} \mathbf{W}^{lk} (\mathbf{x}_j - \mathbf{x}_i) \tilde{\mathbf{H}}_{\text{in},j}^{(k)}$$

$$\mathbf{W}^{lk}(\mathbf{x}) = \sum_{J=|k-l|}^{k+l} \phi_J^{lk}(\|\mathbf{x}\|) \sum_{m=-J}^J Y_{Jm}(\mathbf{x}/\|\mathbf{x}\|) \mathbf{Q}_{Jm}^{lk}$$

$\tilde{\mathbf{H}}_{\text{in},i}^{(l)} \in \mathbb{R}^{2l+1}$  : type- $l$  入力  
( $l$ 階テンソルに対応)

$\mathbf{x}_i$  :  $i$  番目ノード位置

$w^{ll}$  : 学習するパラメータ

$\phi_J^{lk} : \mathbb{R}_{\geq 0} \rightarrow \mathbb{R}$  : 学習する関数

$Y_J : \mathbb{R}^3 \rightarrow \mathbb{R}^{2J+1}$  : 球面調和関数

$\mathbf{Q}_{Jm}^{lk} \in \mathbb{R}^{(2l+1) \times (2k+1)}$  :  
Clebsch-Gordan 係数

# Tensor field network: 合同変換同変な機械学習モデル

- TFN: Tensor field network (Thomas+ 2018)
  - 球面調和関数を用いた  
合同変換不变・同変な機械学習モデル

$$\tilde{\mathbf{H}}_{\text{out},i}^{(l)} = w^{ll} \tilde{\mathbf{H}}_{\text{in},i}^{(l)} + \sum_{k \geq 0} \sum_{j \neq i} \mathbf{W}^{lk}(\mathbf{x}_j - \mathbf{x}_i) \tilde{\mathbf{H}}_{\text{in},j}^{(k)}$$

$$\mathbf{W}^{lk}(\mathbf{x}) = \sum_{J=|k-l|}^{k+l} \phi_J^{lk}(\|\mathbf{x}\|) \sum_{m=-J}^J Y_{Jm}(\mathbf{x}/\|\mathbf{x}\|) \mathbf{Q}_{Jm}^{lk}$$

$\tilde{\mathbf{H}}_{\text{in},i}^{(l)} \in \mathbb{R}^{2l+1}$  : type- $l$  入力  
( $l$ 階テンソルに対応)

$\mathbf{x}_i$  :  $i$  番目ノード位置

$w^{ll}$  : 学習するパラメータ

$\phi_J^{lk} : \mathbb{R}_{\geq 0} \rightarrow \mathbb{R}$  : 学習する関数

$Y_J : \mathbb{R}^3 \rightarrow \mathbb{R}^{2J+1}$  : 球面調和関数

$\mathbf{Q}_{Jm}^{lk} \in \mathbb{R}^{(2l+1) \times (2k+1)}$  :  
Clebsch-Gordan 係数

type- $J$ と type- $k$  の入力から type- $l$  の出力を返すときの係数

$(J, k, l)$	$(0, 0, 0)$	$\begin{pmatrix} 0, 1, 1 \\ 1, 0, 1 \end{pmatrix}$	$(1, 1, 0)$	$(1, 1, 1)$
対応物	掛け算	ベクトルの スカラー倍	ドット積	クロス積

# Tensor field network: 合同変換同変な機械学習モデル

- TFN: Tensor field network (Thomas+ 2018)
    - 球面調和関数を用いた  
合同変換不变・同変な機械学習モデル
- $$\tilde{\mathbf{H}}_{\text{out},i}^{(l)} = w^{ll} \tilde{\mathbf{H}}_{\text{in},i}^{(l)} + \sum_{k \geq 0} \sum_{j \neq i} \mathbf{W}^{lk}(\mathbf{x}_j - \mathbf{x}_i) \tilde{\mathbf{H}}_{\text{in},j}^{(k)}$$
- $$\mathbf{W}^{lk}(\mathbf{x}) = \sum_{J=|k-l|}^{k+l} \phi_J^{lk}(\|\mathbf{x}\|) \sum_{m=-J}^J Y_{Jm}(\mathbf{x}/\|\mathbf{x}\|) \mathbf{Q}_{Jm}^{lk}$$
- $\tilde{\mathbf{H}}_{\text{in},i}^{(l)} \in \mathbb{R}^{2l+1}$  : type- $l$  入力  
( $l$ 階テンソルに対応)
- $\mathbf{x}_i$  :  $i$  番目ノード位置
- $w^{ll}$  : 学習するパラメータ
- $\phi_J^{lk} : \mathbb{R}_{\geq 0} \rightarrow \mathbb{R}$  : 学習する関数
- $Y_J : \mathbb{R}^3 \rightarrow \mathbb{R}^{2J+1}$  : 球面調和関数
- $\mathbf{Q}_{Jm}^{lk} \in \mathbb{R}^{(2l+1) \times (2k+1)}$  : Clebsch-Gordan 係数

- Universality (同変な連続関数を任意の精度で一様に近似できる性質)が示されている (Dym+ 2020)
- 計算に時間がかかるためシミュレーションの代替には不向き

# 目次

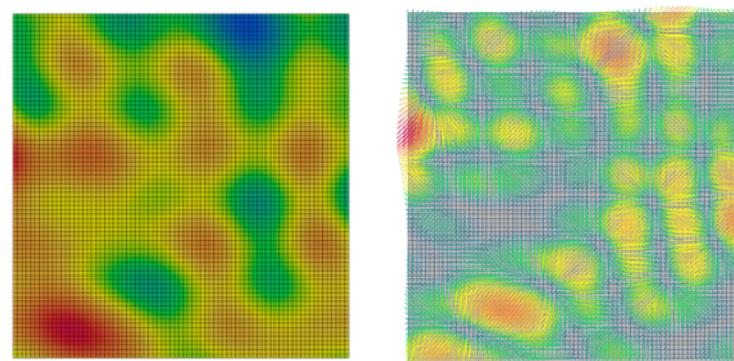
- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

# 目次

- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

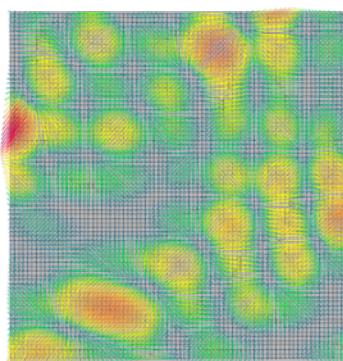
# 概要：対称性があり計算効率のよい GNN を開発

- IsoGCN: 合同変換不变・同変で計算効率のよい GNN (Horie+ 2020)
- IsoGCN は同等の精度の有限要素解析より高速
- IsoGCN は微分演算子の近似とみなせる

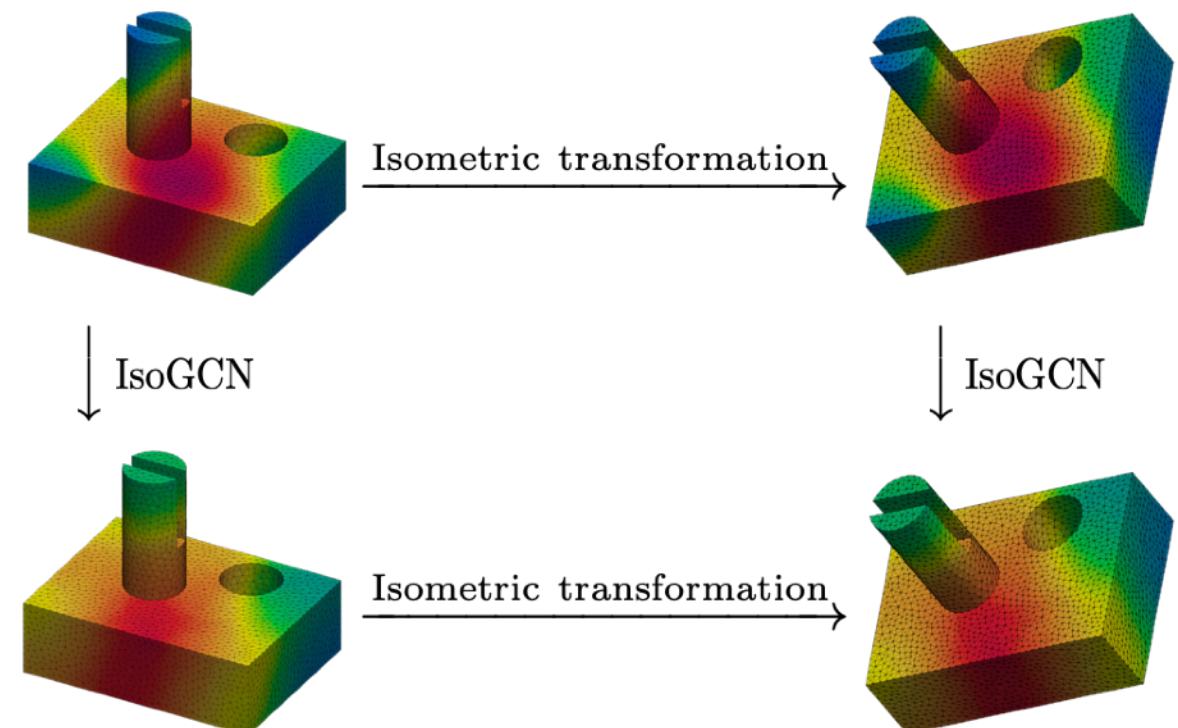


スカラー場  
(入力)

勾配  
(正解)



勾配  
(推論)



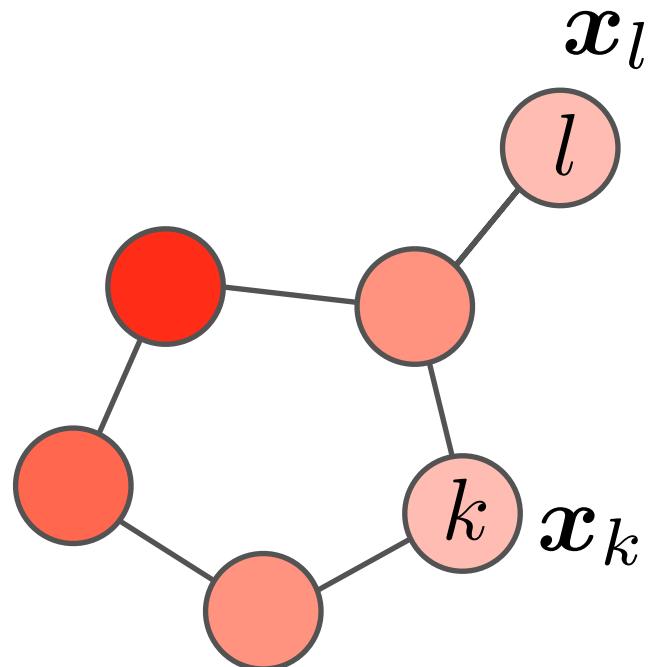
# IsoGCN：合同変換不变・同変な GCN

頂点数  $|\mathcal{V}|$  のグラフが  $d$  次元ユークリッド空間に埋め込まれているとする

- IsoAM (Isometric Adjacency Matrix)  $G$  :

$$G \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}| \times d}$$

$$G_{ijm} = \sum_{k,l; k \neq l} [T_{ijkl}(\mathbf{x}_k - \mathbf{x}_l)]_m$$



# IsoGCN：合同変換不变・同変な GCN

頂点数  $|\mathcal{V}|$  のグラフが  $d$  次元ユークリッド空間に埋め込まれているとする

- IsoAM (Isometric Adjacency Matrix)  $G$  :

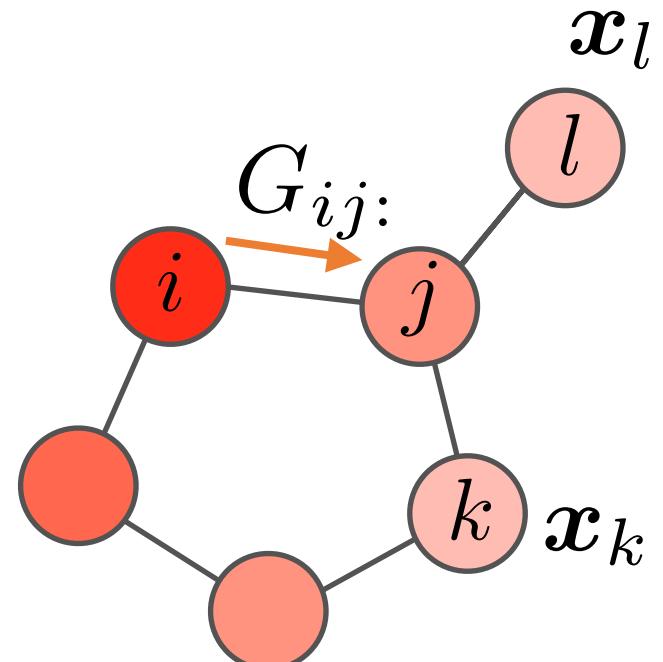
$$G \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}| \times d}$$

$$G_{ijm} = \sum_{k,l; k \neq l} [T_{ijkl}(\mathbf{x}_k - \mathbf{x}_l)]_m$$

- $T_{ijkl}$  : グラフごとに定まる 2 階テンソル

- $T_{ijkl} = \delta_{il}\delta_{jk} \mathbf{I}$  とおけば

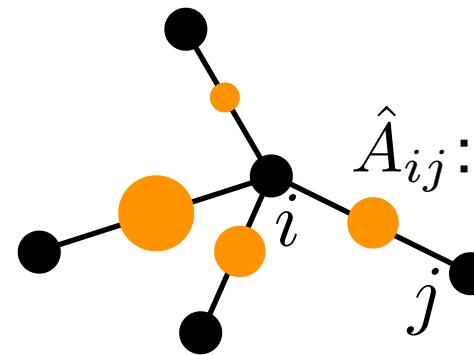
$$G_{ij:} = \mathbf{x}_j - \mathbf{x}_i$$



# Key Idea: GCN with Vector-Valued Adjacency Matrix

- GCN's message passing

$$H_{\text{out}} = \hat{A} H_{\text{in}} W$$

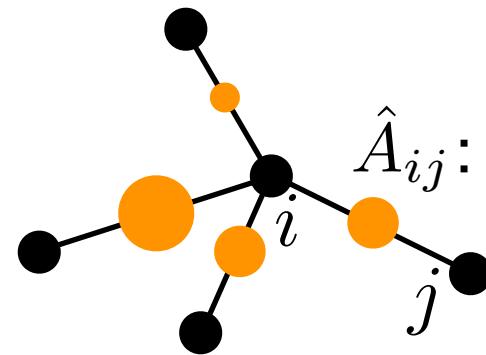


$\hat{A}_{ij}$ : Renormalized adjacency matrix

# Key Idea: GCN with Vector-Valued Adjacency Matrix

- GCN's message passing

$$H_{\text{out}} = \hat{A} H_{\text{in}} W$$

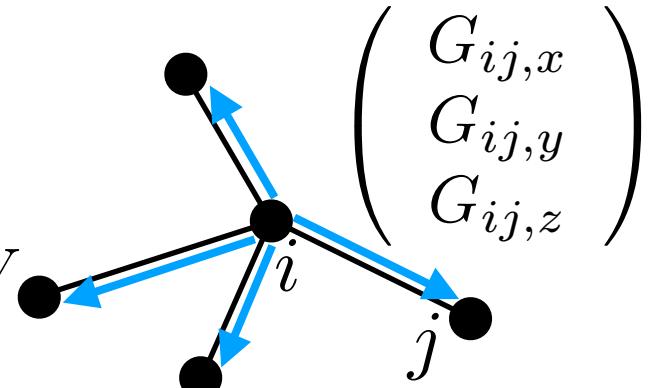


$\hat{A}_{ij}$ : Renormalized adjacency matrix

- IsoGCN's message passing:

- Scalar to vector

$$\begin{pmatrix} H_{\text{out},x} \\ H_{\text{out},y} \\ H_{\text{out},z} \end{pmatrix} = \begin{pmatrix} G_{::,x} \\ G_{::,y} \\ G_{::,z} \end{pmatrix} H_{\text{in}} W$$

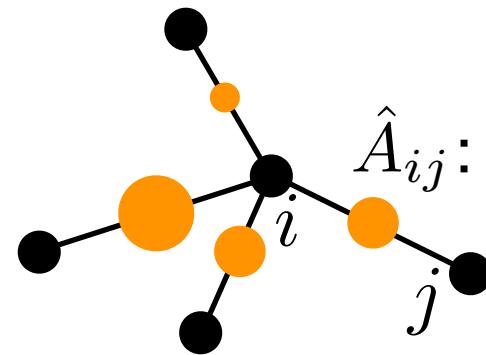


IsoAM :  
relative vertex positions

# Key Idea: GCN with Vector-Valued Adjacency Matrix

- GCN's message passing

$$H_{\text{out}} = \hat{A} H_{\text{in}} W$$

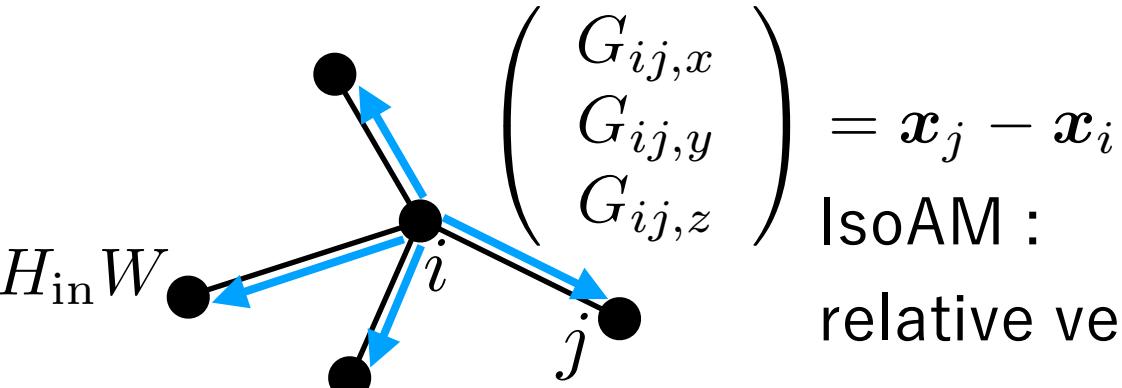


$\hat{A}_{ij}$ : Renormalized adjacency matrix

- IsoGCN's message passing:

- Scalar to vector

$$\begin{pmatrix} H_{\text{out},x} \\ H_{\text{out},y} \\ H_{\text{out},z} \end{pmatrix} = \begin{pmatrix} G_{::,x} \\ G_{::,y} \\ G_{::,z} \end{pmatrix}$$



$$= \mathbf{x}_j - \mathbf{x}_i$$

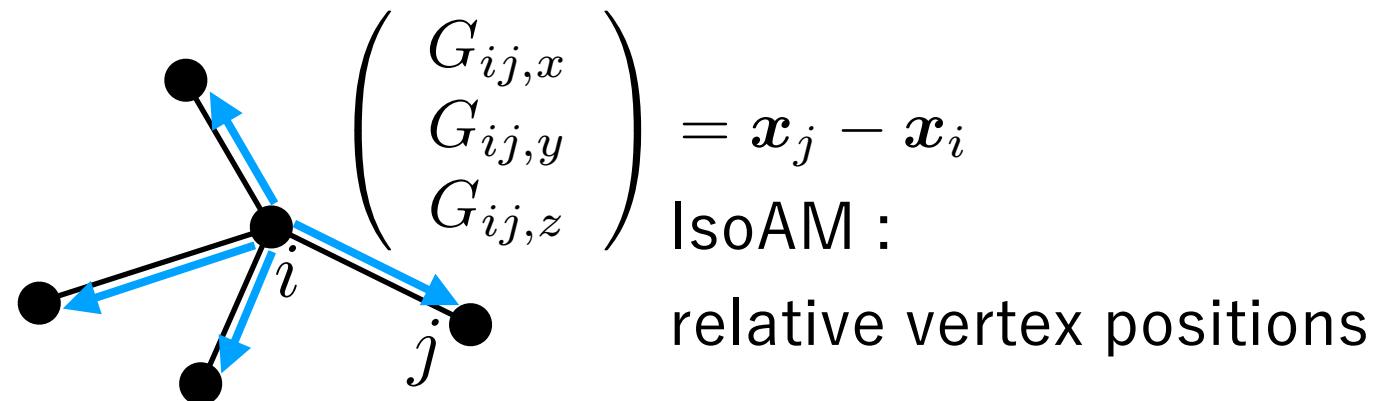
IsoAM :

relative vertex positions

# Key Idea: GCN with Vector-Valued Adjacency Matrix

- GCN's message passing

$$H_{\text{out}} = \hat{A} H_{\text{in}} W$$



- IsoGCN's message passing:

- Scalar to vector

$$\begin{pmatrix} H_{\text{out},x} \\ H_{\text{out},y} \\ H_{\text{out},z} \end{pmatrix} = \begin{pmatrix} G_{::,x} \\ G_{::,y} \\ G_{::,z} \end{pmatrix} H_{\text{in}} W$$

- IsoGCN incorporates graphs' geometry information by simply replacing the adjacency matrices with IsoAMs

# Key Idea: GCN with Vector-Valued Adjacency Matrix

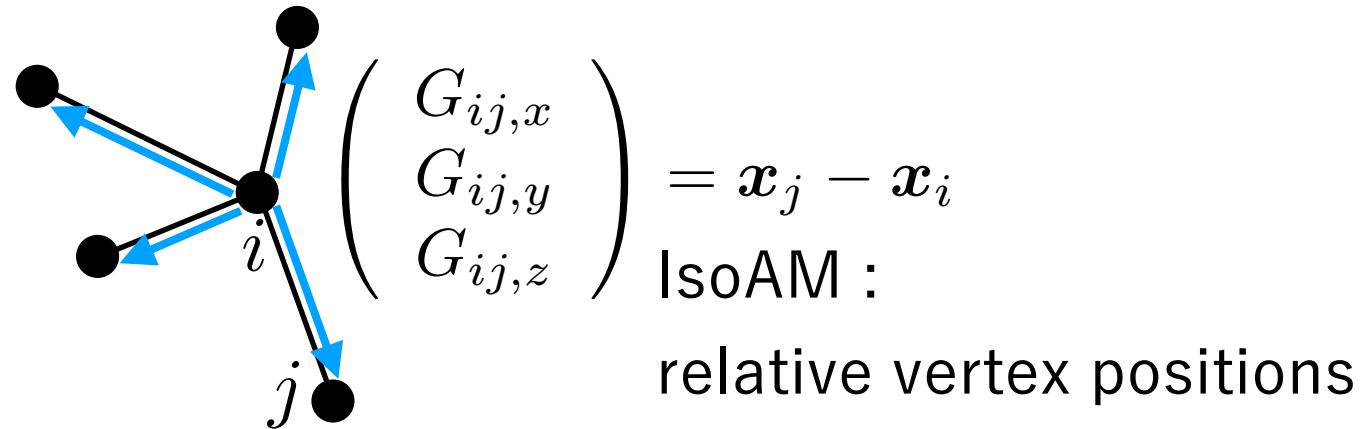
- GCN's message passing

$$H_{\text{out}} = \hat{A} H_{\text{in}} W$$

- IsoGCN's message passing:

- Scalar to vector

$$\begin{pmatrix} H_{\text{out},x} \\ H_{\text{out},y} \\ H_{\text{out},z} \end{pmatrix} = \begin{pmatrix} G_{::,x} \\ G_{::,y} \\ G_{::,z} \end{pmatrix} H_{\text{in}} W$$

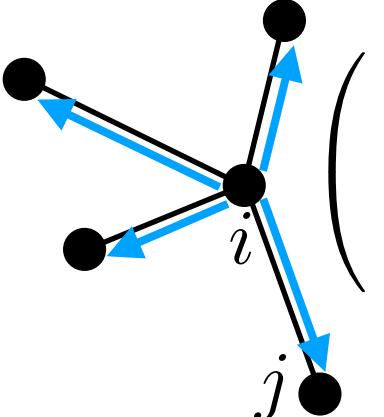


- IsoGCN incorporates graphs' geometry information by simply replacing the adjacency matrices with IsoAMs
    - IsoAM is equivariant

# Key Idea: GCN with Vector-Valued Adjacency Matrix

- IsoGCN's message passing:

- Scalar to vector

$$\begin{pmatrix} H_{\text{out},x} \\ H_{\text{out},y} \\ H_{\text{out},z} \end{pmatrix} = \begin{pmatrix} G_{::,x} \\ G_{::,y} \\ G_{::,z} \end{pmatrix} H_{\text{in}} W$$


$$\begin{pmatrix} G_{ij,x} \\ G_{ij,y} \\ G_{ij,z} \end{pmatrix} = \mathbf{x}_j - \mathbf{x}_i$$

IsoAM :  
relative vertex positions

- Vector to scalar

$$H_{\text{out}} = \begin{pmatrix} G_{::,x} \\ G_{::,y} \\ G_{::,z} \end{pmatrix} \cdot \begin{pmatrix} H_{\text{in},x} \\ H_{\text{in},y} \\ H_{\text{in},z} \end{pmatrix} W$$

- IsoGCN can convert any rank tensors to any rank tensors with keeping equivariance

- Scalar to rank-2 tensor

$$\begin{pmatrix} H_{\text{out},xx} & H_{\text{out},xy} & H_{\text{out},xz} \\ H_{\text{out},yx} & H_{\text{out},yy} & H_{\text{out},yz} \\ H_{\text{out},zx} & H_{\text{out},zy} & H_{\text{out},zz} \end{pmatrix} = \begin{pmatrix} G_{::,x}G_{::,x} & G_{::,x}G_{::,y} & G_{::,x}G_{::,z} \\ G_{::,y}G_{::,x} & G_{::,y}G_{::,y} & G_{::,y}G_{::,z} \\ G_{::,z}G_{::,x} & G_{::,z}G_{::,y} & G_{::,z}G_{::,z} \end{pmatrix} H_{\text{in}} W$$

# IsoGCN：合同変換不变・同変な GCN

- 有限要素解析に適用するため  
IsoAM の具体例  $\tilde{D}_{ijk}$  を以下のように定義する

$$\tilde{D}_{ijk} = D_{ijk} - \delta_{ij} \sum_l D_{ilk}$$

$$D_{ijk} = M^{-1} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|^2} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij}$$

$$M_i = \sum_l \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \otimes \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{il}$$

# IsoGCN：合同変換不变・同変な GCN

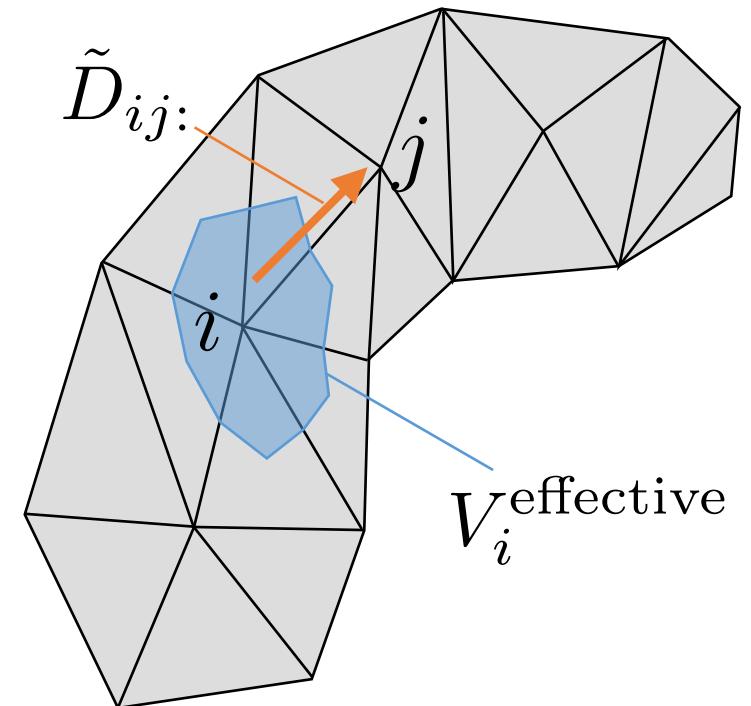
- 有限要素解析に適用するため  
IsoAM の具体例  $\tilde{D}_{ijk}$  を以下のように定義する

$$\tilde{D}_{ijk} = D_{ijk} - \delta_{ij} \sum_l D_{ilk}$$

$$D_{ijk} = M^{-1} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|^2} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij}$$

$$M_i = \sum_l \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \otimes \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{il}$$

$A$  : 隣接行列  
 $V_i^{\text{effective}}$ : 頂点 i の体積



# IsoGCN：合同変換不变・同変な GCN

- 有限要素解析に適用するため  
IsoAM の具体例  $\tilde{D}_{ijk}$  を以下のように定義する

$$\tilde{D}_{ijk} = D_{ijk} - \delta_{ij} \sum_l D_{ilk}$$

$$D_{ijk} = M^{-1} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|^2} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij}$$

$$M_i = \sum_l \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \otimes \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{il}$$

- $\tilde{D}$  がナブラ演算子の離散化 (Tamai+ 2014) に対応している

$$\left\langle \frac{\partial \phi}{\partial x_k} \right\rangle_i := M_i^{-1} \sum_j \frac{\phi_j - \phi_i}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij} = \sum_j \tilde{D}_{ijk} \phi_j$$

# IsoGCN：合同変換不变・同変な GCN

- 有限要素解析に適用するため  
IsoAM の具体例  $\tilde{D}_{ijk}$  を以下のように定義する

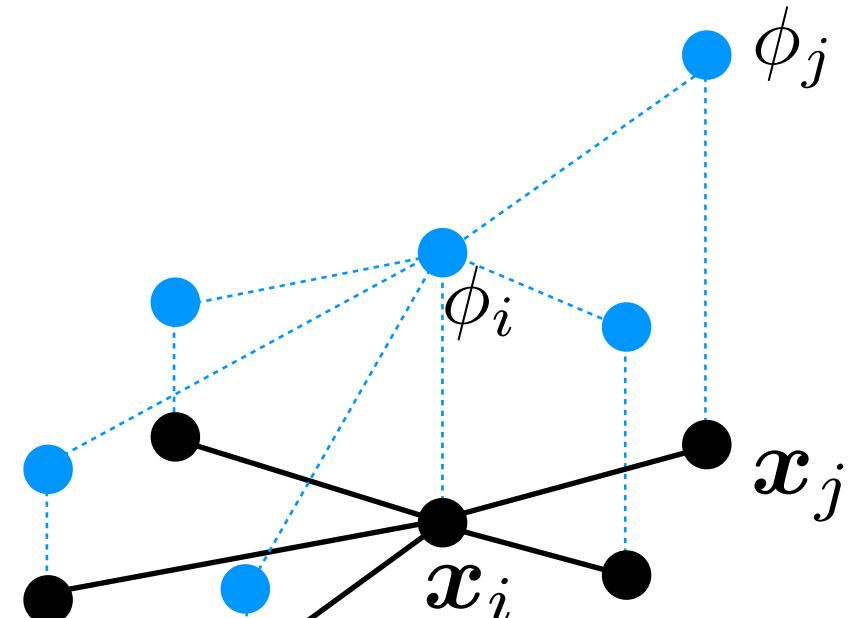
$$\tilde{D}_{ijk} = D_{ijk} - \delta_{ij} \sum_l D_{ilk}$$

$$D_{ijk} = M^{-1} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|^2} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij}$$

$$M_i = \sum_l \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \otimes \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{il}$$

- $\tilde{D}$  がナブラ演算子の離散化 (Tamai+ 2014) に対応している

$$\left\langle \frac{\partial \phi}{\partial x_k} \right\rangle_i := M_i^{-1} \sum_j \frac{\phi_j - \phi_i}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij} = \sum_j \tilde{D}_{ijk} \phi_j$$



# IsoGCN：合同変換不变・同変な GCN

- 有限要素解析に適用するため  
IsoAM の具体例  $\tilde{D}_{ijk}$  を以下のように定義する

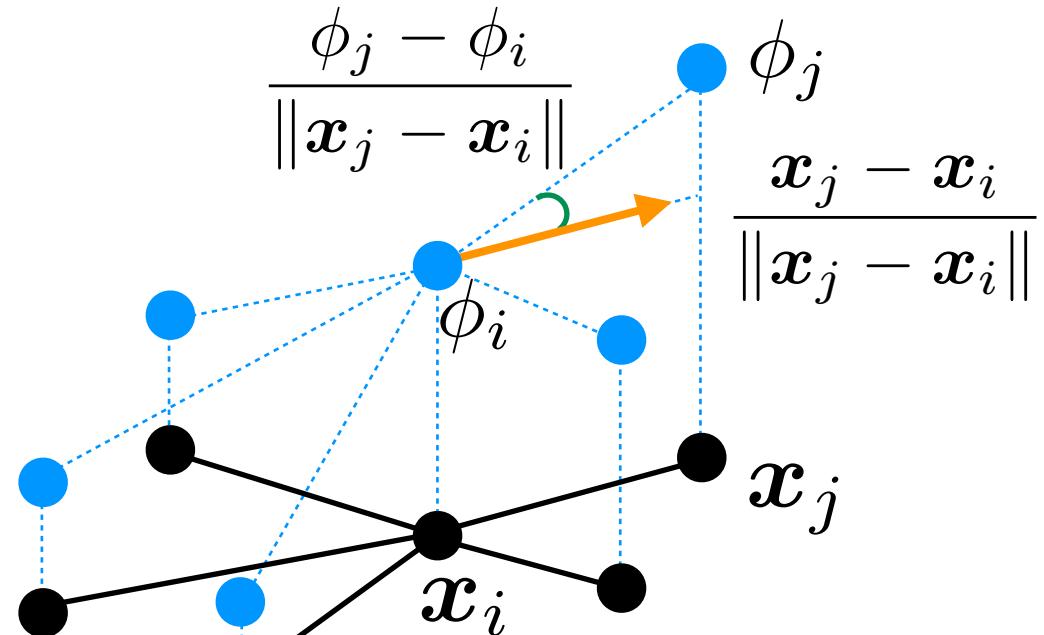
$$\tilde{D}_{ijk} = D_{ijk} - \delta_{ij} \sum_l D_{ilk}$$

$$D_{ijk} = M^{-1} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|^2} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij}$$

$$M_i = \sum_l \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \otimes \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{il}$$

- $\tilde{D}$  がナブラ演算子の離散化 (Tamai+ 2014) に対応している

$$\left\langle \frac{\partial \phi}{\partial x_k} \right\rangle_i := M_i^{-1} \sum_j \frac{\phi_j - \phi_i}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij} = \sum_j \tilde{D}_{ijk} \phi_j$$



# IsoGCN：合同変換不变・同変な GCN

- 有限要素解析に適用するため  
IsoAM の具体例  $\tilde{D}_{ijk}$  を以下のように定義する

$$\tilde{D}_{ijk} = D_{ijk} - \delta_{ij} \sum_l D_{ilk}$$

$$D_{ijk} = M^{-1} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|^2} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij}$$

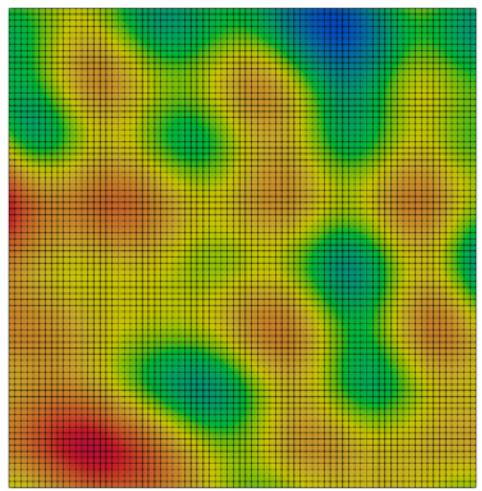
$$M_i = \sum_l \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \otimes \frac{\mathbf{x}_l - \mathbf{x}_i}{\|\mathbf{x}_l - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{il}$$

- $\tilde{D}$  がナブラ演算子の離散化 (Tamai+ 2014) に対応している

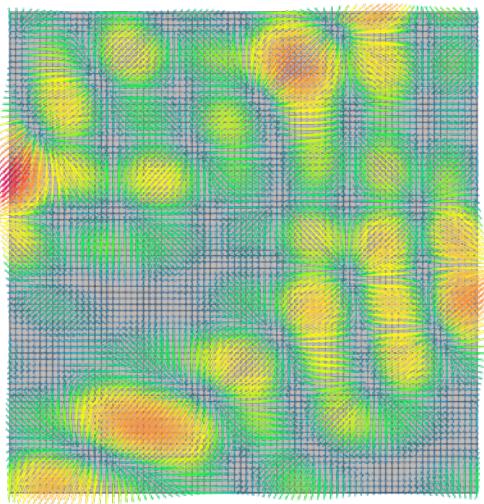
$$\left\langle \frac{\partial \phi}{\partial x_k} \right\rangle_i := M_i^{-1} \sum_j \frac{\phi_j - \phi_i}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{x_{jk} - x_{ik}}{\|\mathbf{x}_j - \mathbf{x}_i\|} \frac{V_j^{\text{effective}}}{V_i^{\text{effective}}} A_{ij} = \sum_j \tilde{D}_{ijk} \phi_j$$

Differential op.	Expression
Gradient	$\tilde{\mathbf{D}} * \mathbf{H}^{(0)}$
Divergence	$\tilde{\mathbf{D}} \odot \mathbf{H}^{(1)}$
Laplacian	$\tilde{\mathbf{D}} \odot \tilde{\mathbf{D}} \mathbf{H}^{(0)}$
Jacobian	$\tilde{\mathbf{D}} \otimes \mathbf{H}^{(1)}$
Hessian	$\tilde{\mathbf{D}} \otimes \tilde{\mathbf{D}} * \mathbf{H}^{(0)}$

# 実験：微分演算子の学習



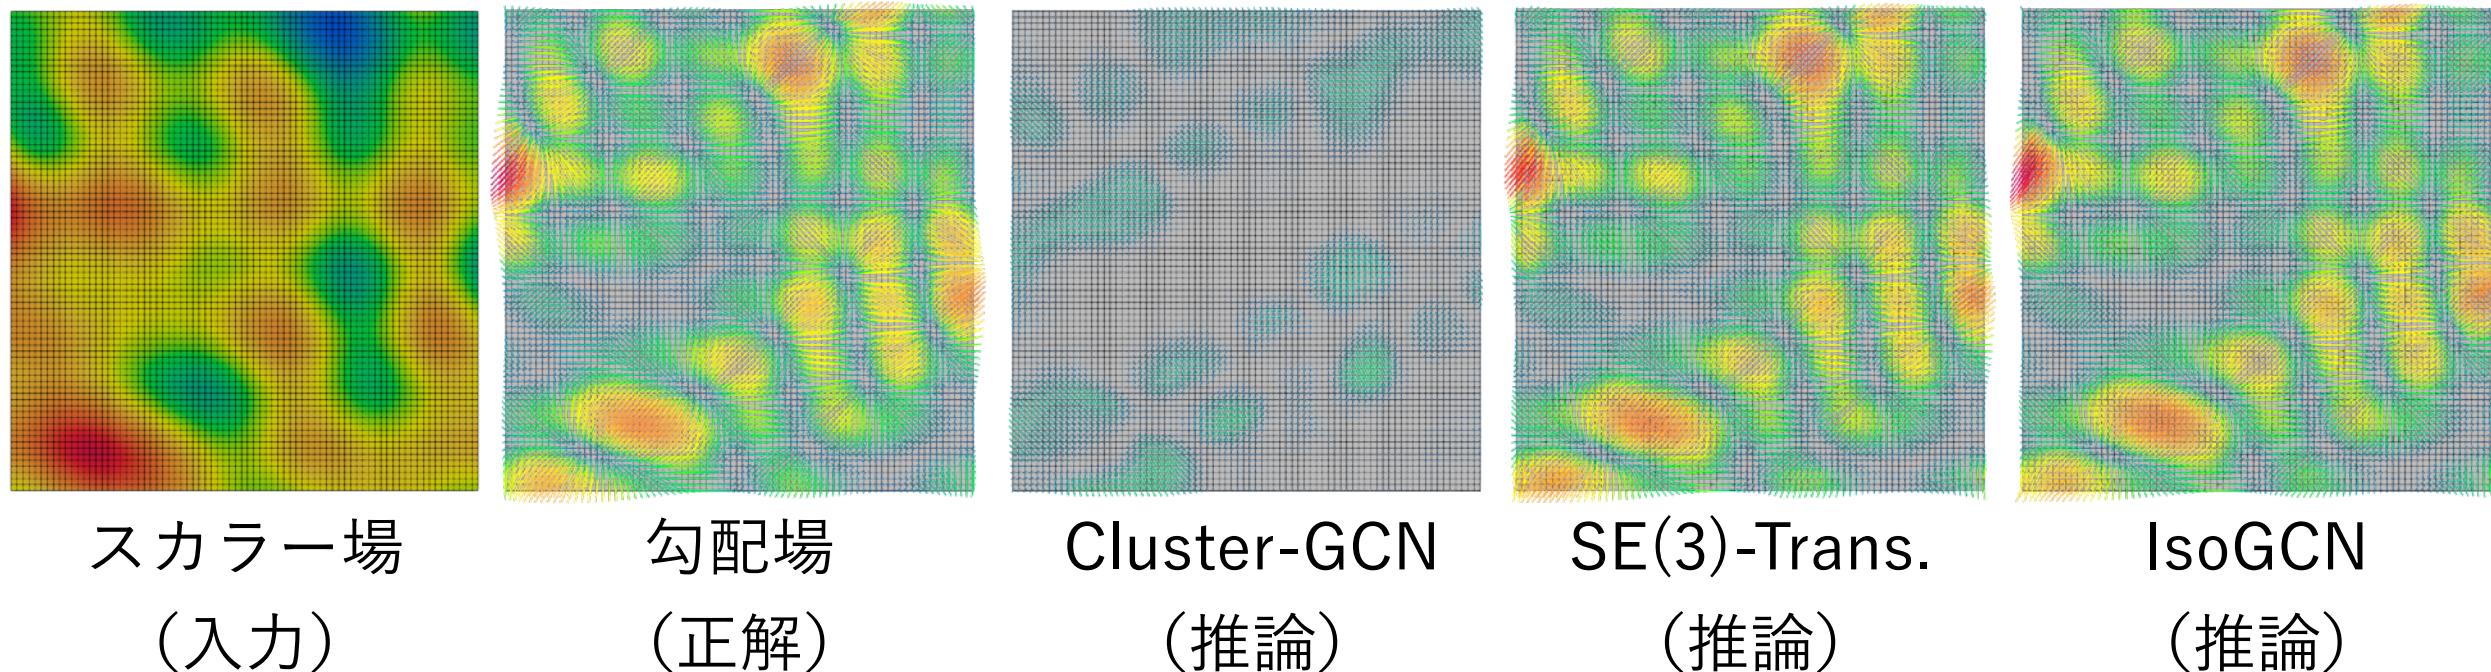
スカラー場  
(入力)



勾配場  
(正解)

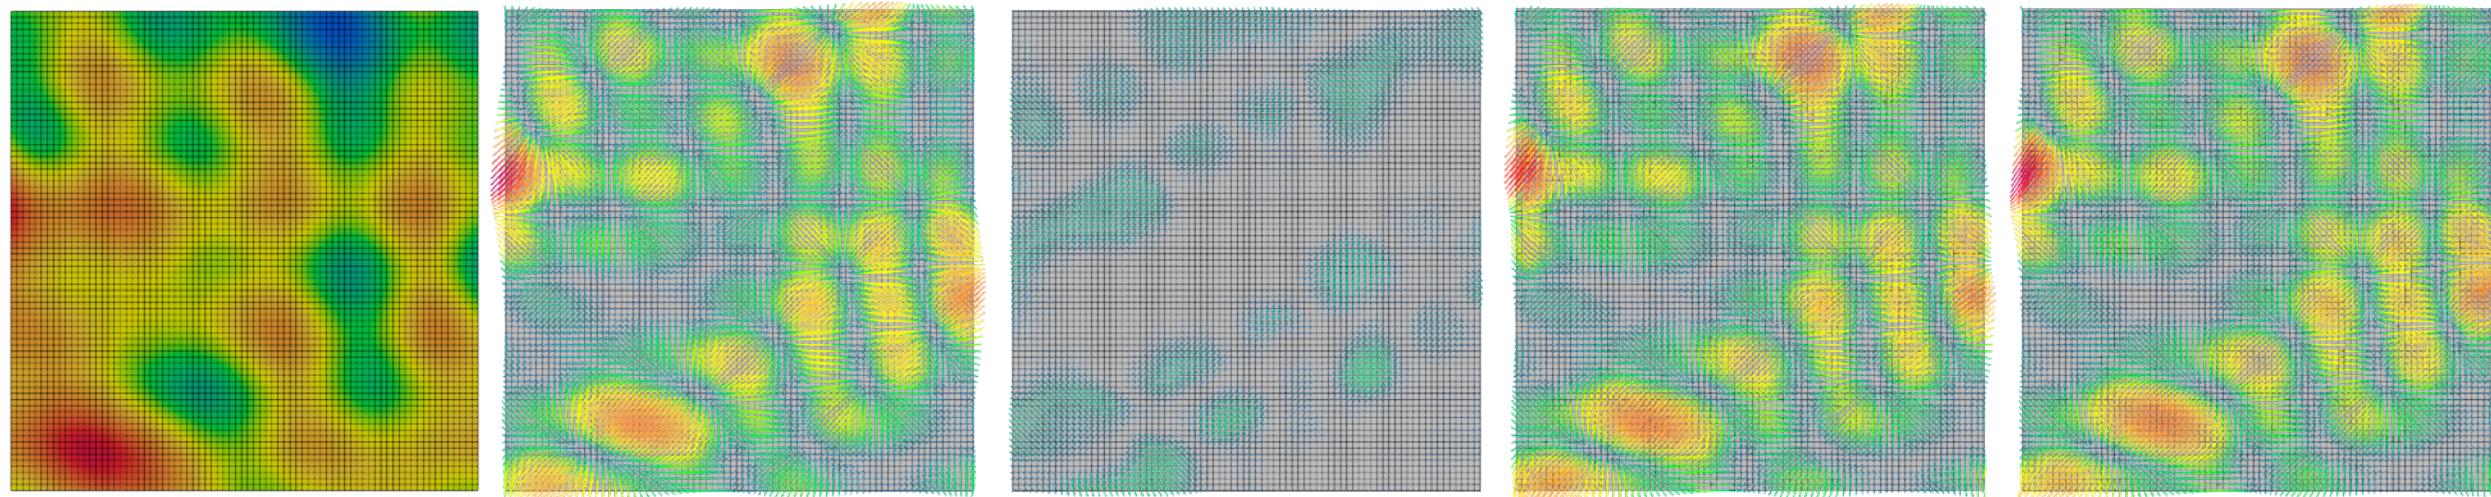
- X、Y 方向に 10 ~ 100 要素ある  
グリッドメッシュをランダムに生成
- ランダムなフーリエ級数で  
スカラー場を生成
- 微分を解析的に計算
- training、validation、test dataset  
はそれぞれ 100 サンプル

# 実験：微分演算子の学習



- 既存の GCN 系の手法では空間の情報を扱えないが IsoGCN では可能

# 実験：微分演算子の学習



スカラー場  
(入力)

勾配場  
(正解)

Cluster-GCN  
(推論)

SE(3)-Trans.  
(推論)

IsoGCN  
(推論)

100 サンプルの推論時間 :

4.0 s

0.4 s

- 既存の GCN 系の手法では空間の情報を扱えないが IsoGCN では可能

# 実験：微分演算子の学習

Method	# hops	$x$	スカラー	スカラー	勾配	勾配
			↓	↓	↓	↓
			勾配	ヘッシアン	ラプラシアン	ヘッシアン
			<b>Loss of 0 → 1</b> $\times 10^{-5}$	<b>Loss of 0 → 2</b> $\times 10^{-6}$	<b>Loss of 1 → 0</b> $\times 10^{-6}$	<b>Loss of 1 → 2</b> $\times 10^{-6}$
GIN	5	Yes	147.07 ± 0.51	47.35 ± 0.35	404.92 ± 1.74	46.18 ± 0.39
GCNII	5	Yes	151.13 ± 0.53	31.87 ± 0.22	280.61 ± 1.30	39.38 ± 0.34
SGCN	5	Yes	151.16 ± 0.53	55.08 ± 0.42	127.21 ± 0.63	56.97 ± 0.44
GCN	5	Yes	151.14 ± 0.53	48.50 ± 0.35	542.30 ± 2.14	25.37 ± 0.28
Cluster-GCN	5	Yes	146.91 ± 0.51	26.60 ± 0.19	185.21 ± 0.99	18.18 ± 0.20
TFN	2	No	2.47 ± 0.02	OOM	26.69 ± 0.24	OOM
	5	No	OOM	OOM	OOM	OOM
SE(3)-Trans.	2	No	<b>1.79</b> ± 0.02	<b>3.50</b> ± 0.04	<b>2.52</b> ± 0.02	OOM
	5	No	2.12 ± 0.02	OOM	7.66 ± 0.05	OOM
IsoGCN (Ours)	2	No	2.67 ± 0.02	6.37 ± 0.07	7.18 ± 0.06	<b>1.44</b> ± 0.02
	5	No	14.19 ± 0.10	21.72 ± 0.25	34.09 ± 0.19	8.32 ± 0.09

- 既存の GCN 系の手法では空間の情報を扱えないが IsoGCN では可能

# 実験：微分演算子の学習

スカラー



勾配

$0 \rightarrow 1$

スカラー



ヘッシャン

$0 \rightarrow 2$

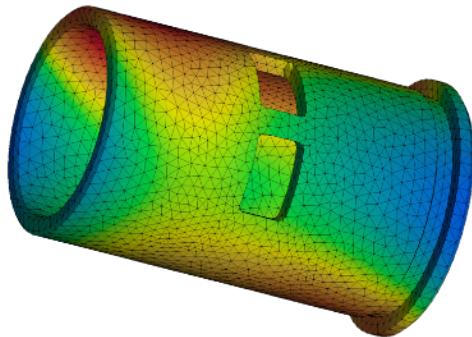
Method	# parameters	Inference time [s]	# parameters	Inference time [s]
TFN	5264	3.8	5220	OOM
SE(3)-Trans.	5392	4.0	5265	9.2
<b>IsoGCN (Ours)</b>	4816	0.4	4816	0.7

- IsoGCN は TFN、SE(3)-Transformer（TFN の改良）より高速

# 実験：非定常・異方的・非線型熱拡散問題

$$\Omega \subset \mathbb{R}^3,$$

初期条件

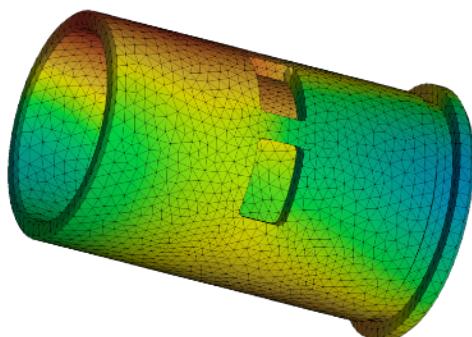


$$\frac{\partial T(\boldsymbol{x}, t)}{\partial t} = \nabla \cdot \boldsymbol{C}(T(\boldsymbol{x}, t)) \nabla T(\boldsymbol{x}, t) \quad \text{in } \Omega,$$

$$T(\boldsymbol{x}, t = 0) = T_{\text{init}}(\boldsymbol{x}) \quad \text{in } \Omega,$$

$$\nabla T(\boldsymbol{x}, t)|_{\boldsymbol{x}=\boldsymbol{x}_b} \cdot \boldsymbol{n}(\boldsymbol{x}_b) = 0 \quad \text{on } \partial\Omega$$

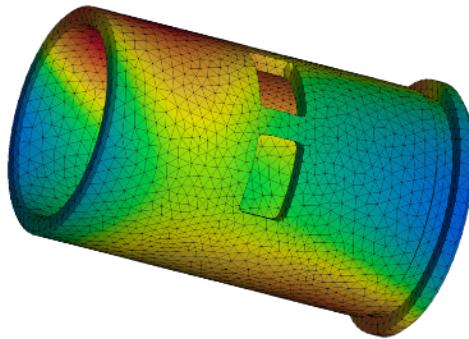
有限要素解析



# 実験：非定常・異方的・非線型熱拡散問題

$$\Omega \subset \mathbb{R}^3,$$

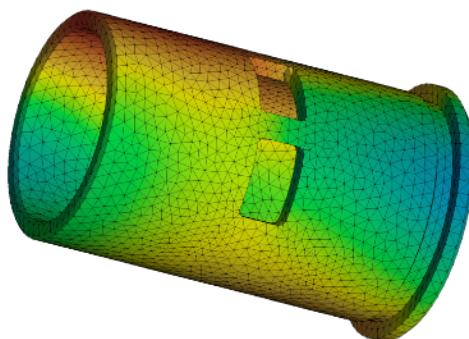
初期条件



$$\nabla T(\mathbf{x}, t = 0) = T_{\text{init}}(\mathbf{x}) \quad \text{in } \Omega,$$

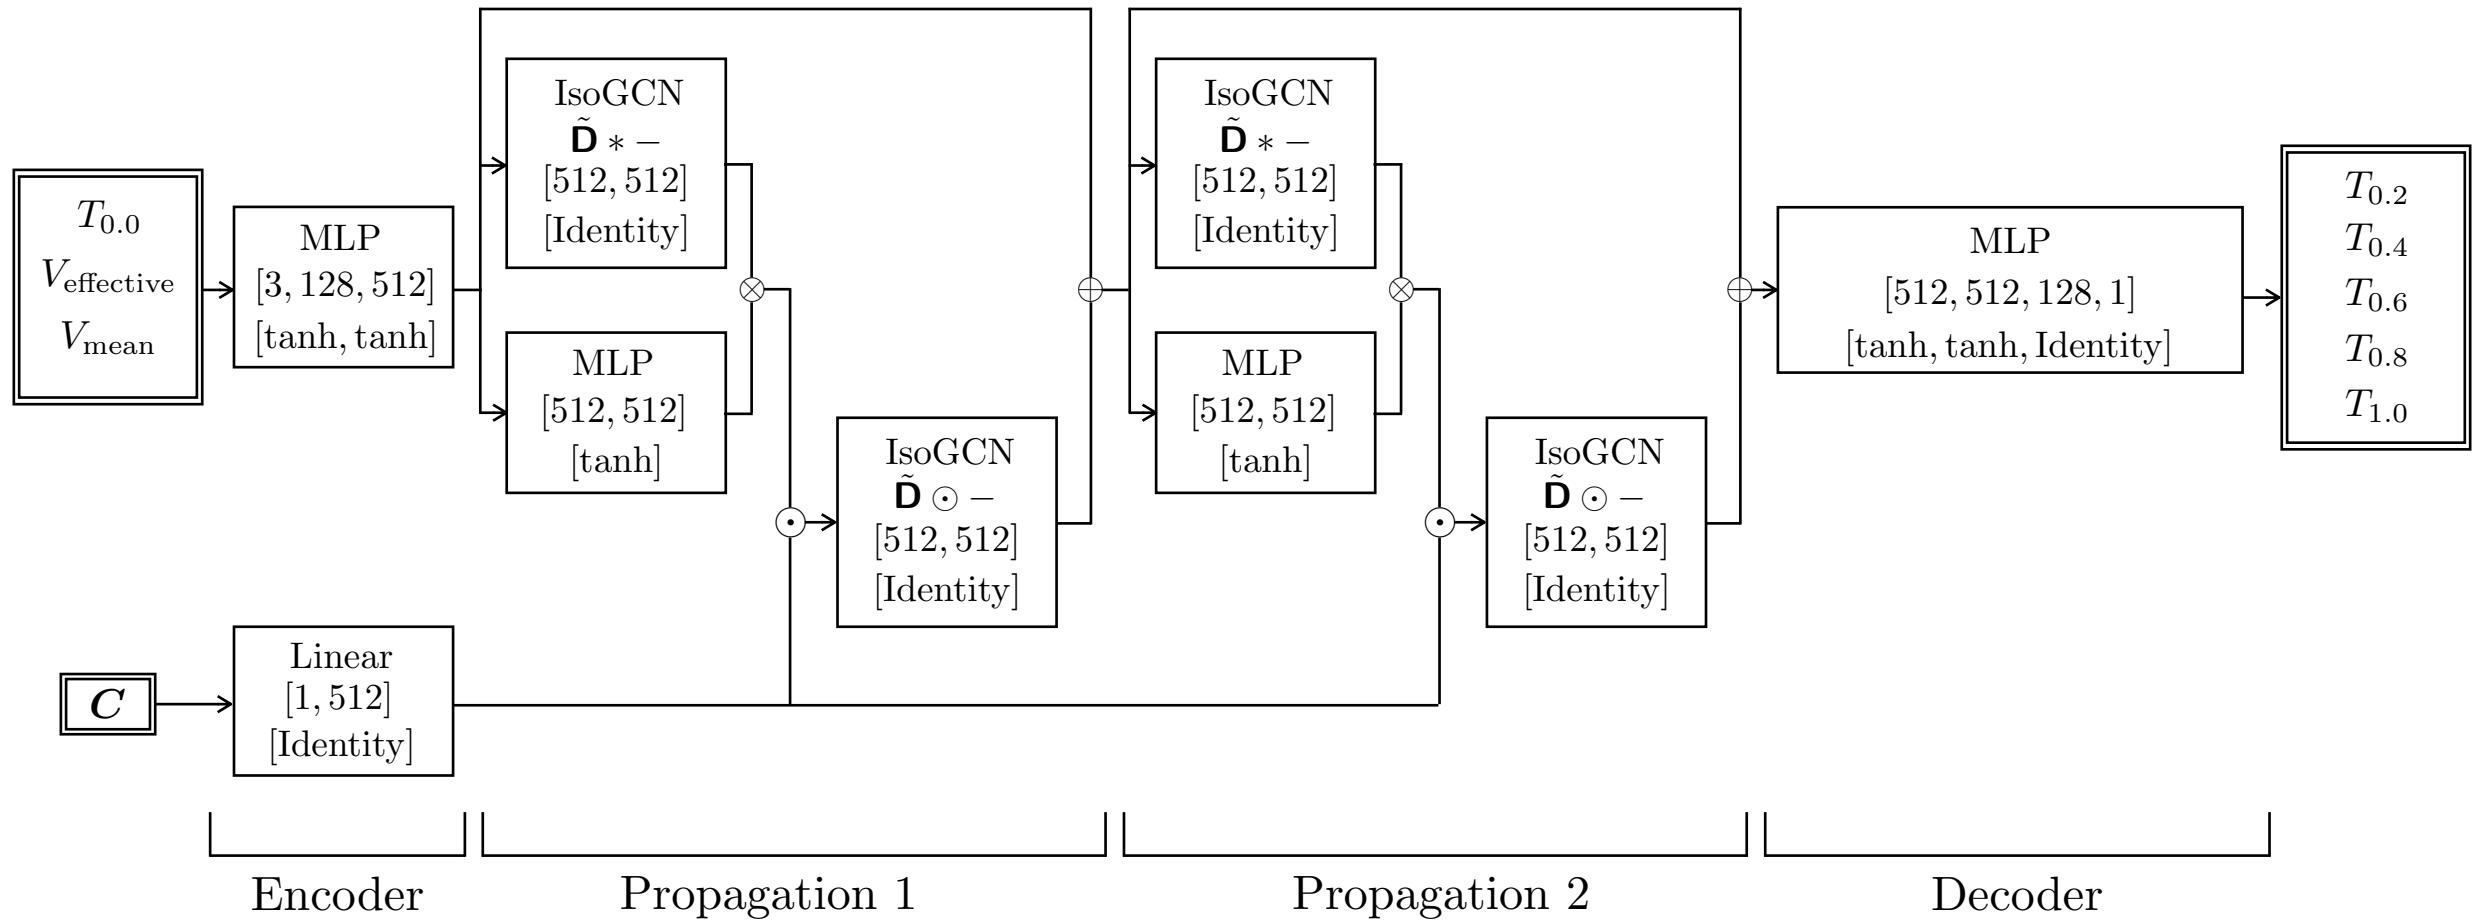
$$\nabla T(\mathbf{x}, t) |_{\mathbf{x}=\mathbf{x}_b} \cdot \mathbf{n}(\mathbf{x}_b) = 0 \quad \text{on } \partial\Omega$$

有限要素解析

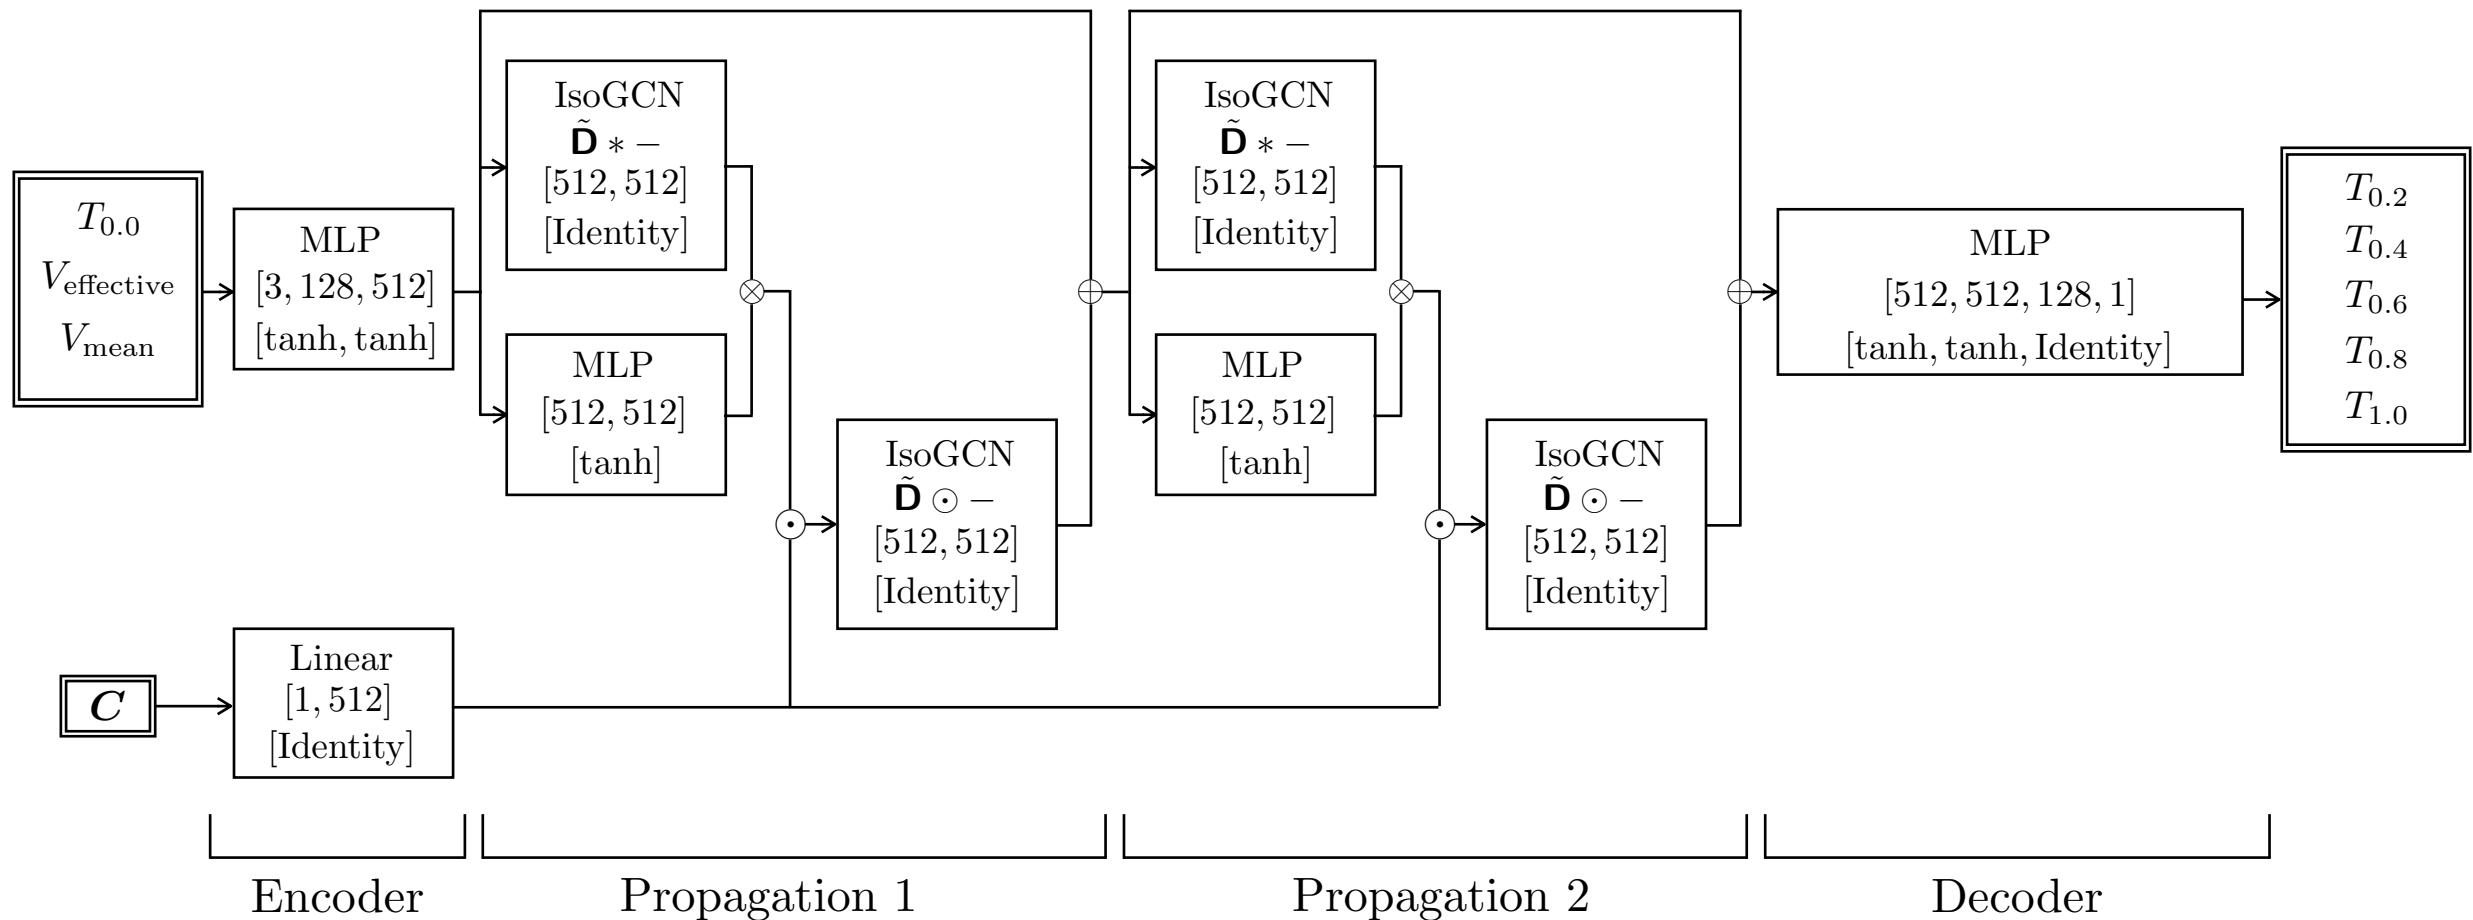


- ABC dataset (Koch+ 2018) から CAD データを抽出
- CAD 形状ひとつにつきメッシュサイズ 3 通り  
初期条件 3 通りの最大 9 サンプルを生成
  - Training dataset: 50 形状、439 サンプル
  - Validation dataset: 16 形状、143 サンプル
  - Test dataset: 16 shapes、140 サンプル

# 実験：非定常・異方的・非線型熱拡散問題



# 実験：非定常・異方的・非線型熱拡散問題

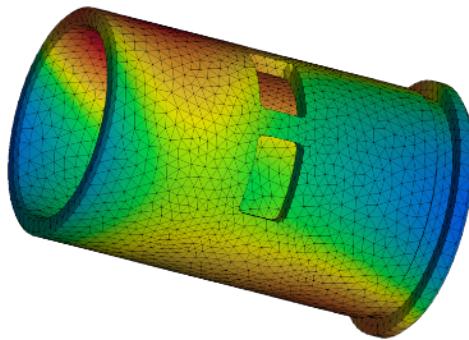


$$T(\mathbf{x}, t + \Delta t) \simeq T(\mathbf{x}, t) + \nabla \cdot \mathbf{C}(T(\mathbf{x}, t)) \nabla T(\mathbf{x}, t) \Delta t$$

# 実験：非定常・異方的・非線型熱拡散問題

$$\Omega \subset \mathbb{R}^3,$$

初期条件

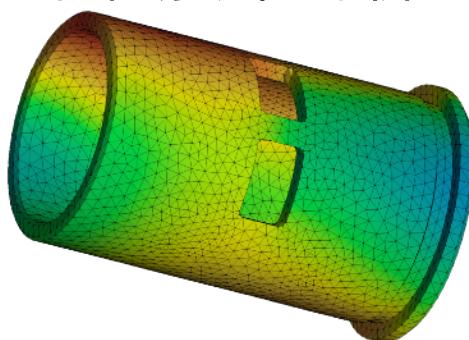


$$\frac{\partial T(\boldsymbol{x}, t)}{\partial t} = \nabla \cdot \boldsymbol{C}(T(\boldsymbol{x}, t)) \nabla T(\boldsymbol{x}, t) \quad \text{in } \Omega,$$

$$T(\boldsymbol{x}, t = 0) = T_{\text{init}}(\boldsymbol{x}) \quad \text{in } \Omega,$$

$$\nabla T(\boldsymbol{x}, t)|_{\boldsymbol{x}=\boldsymbol{x}_b} \cdot \boldsymbol{n}(\boldsymbol{x}_b) = 0 \quad \text{on } \partial\Omega$$

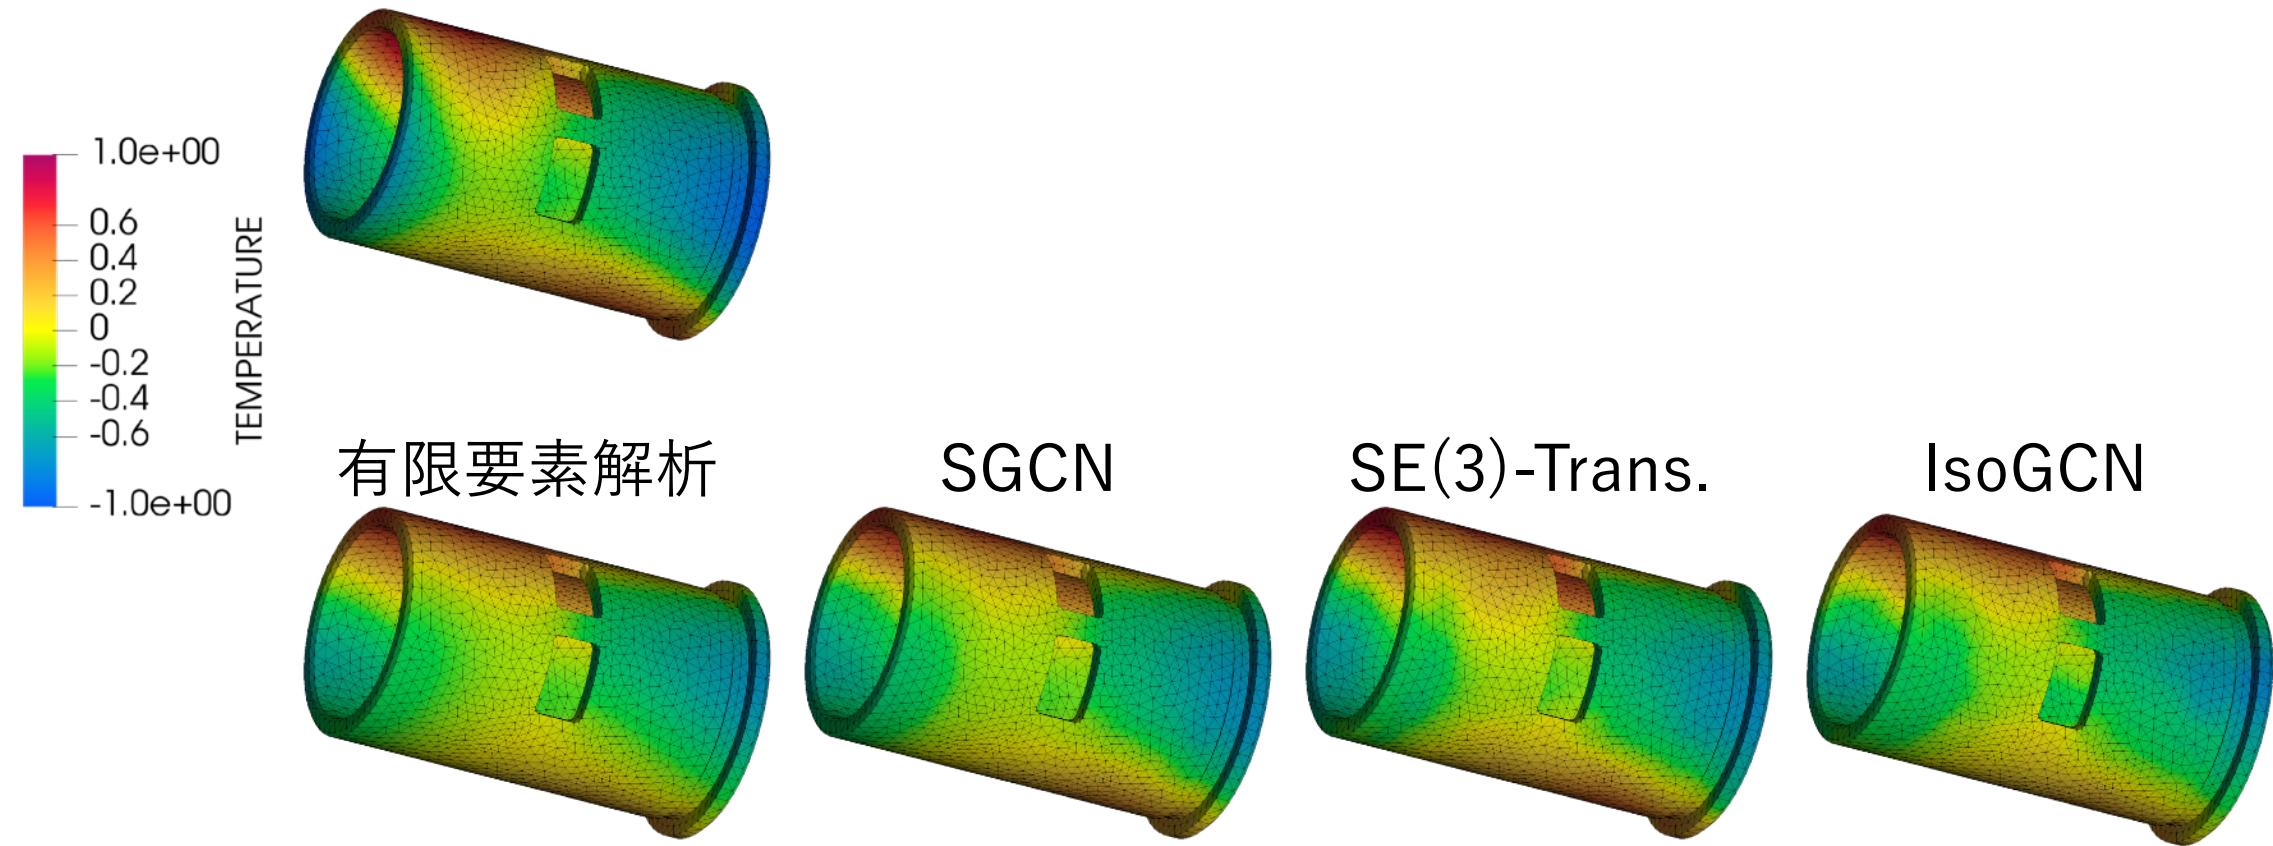
有限要素解析



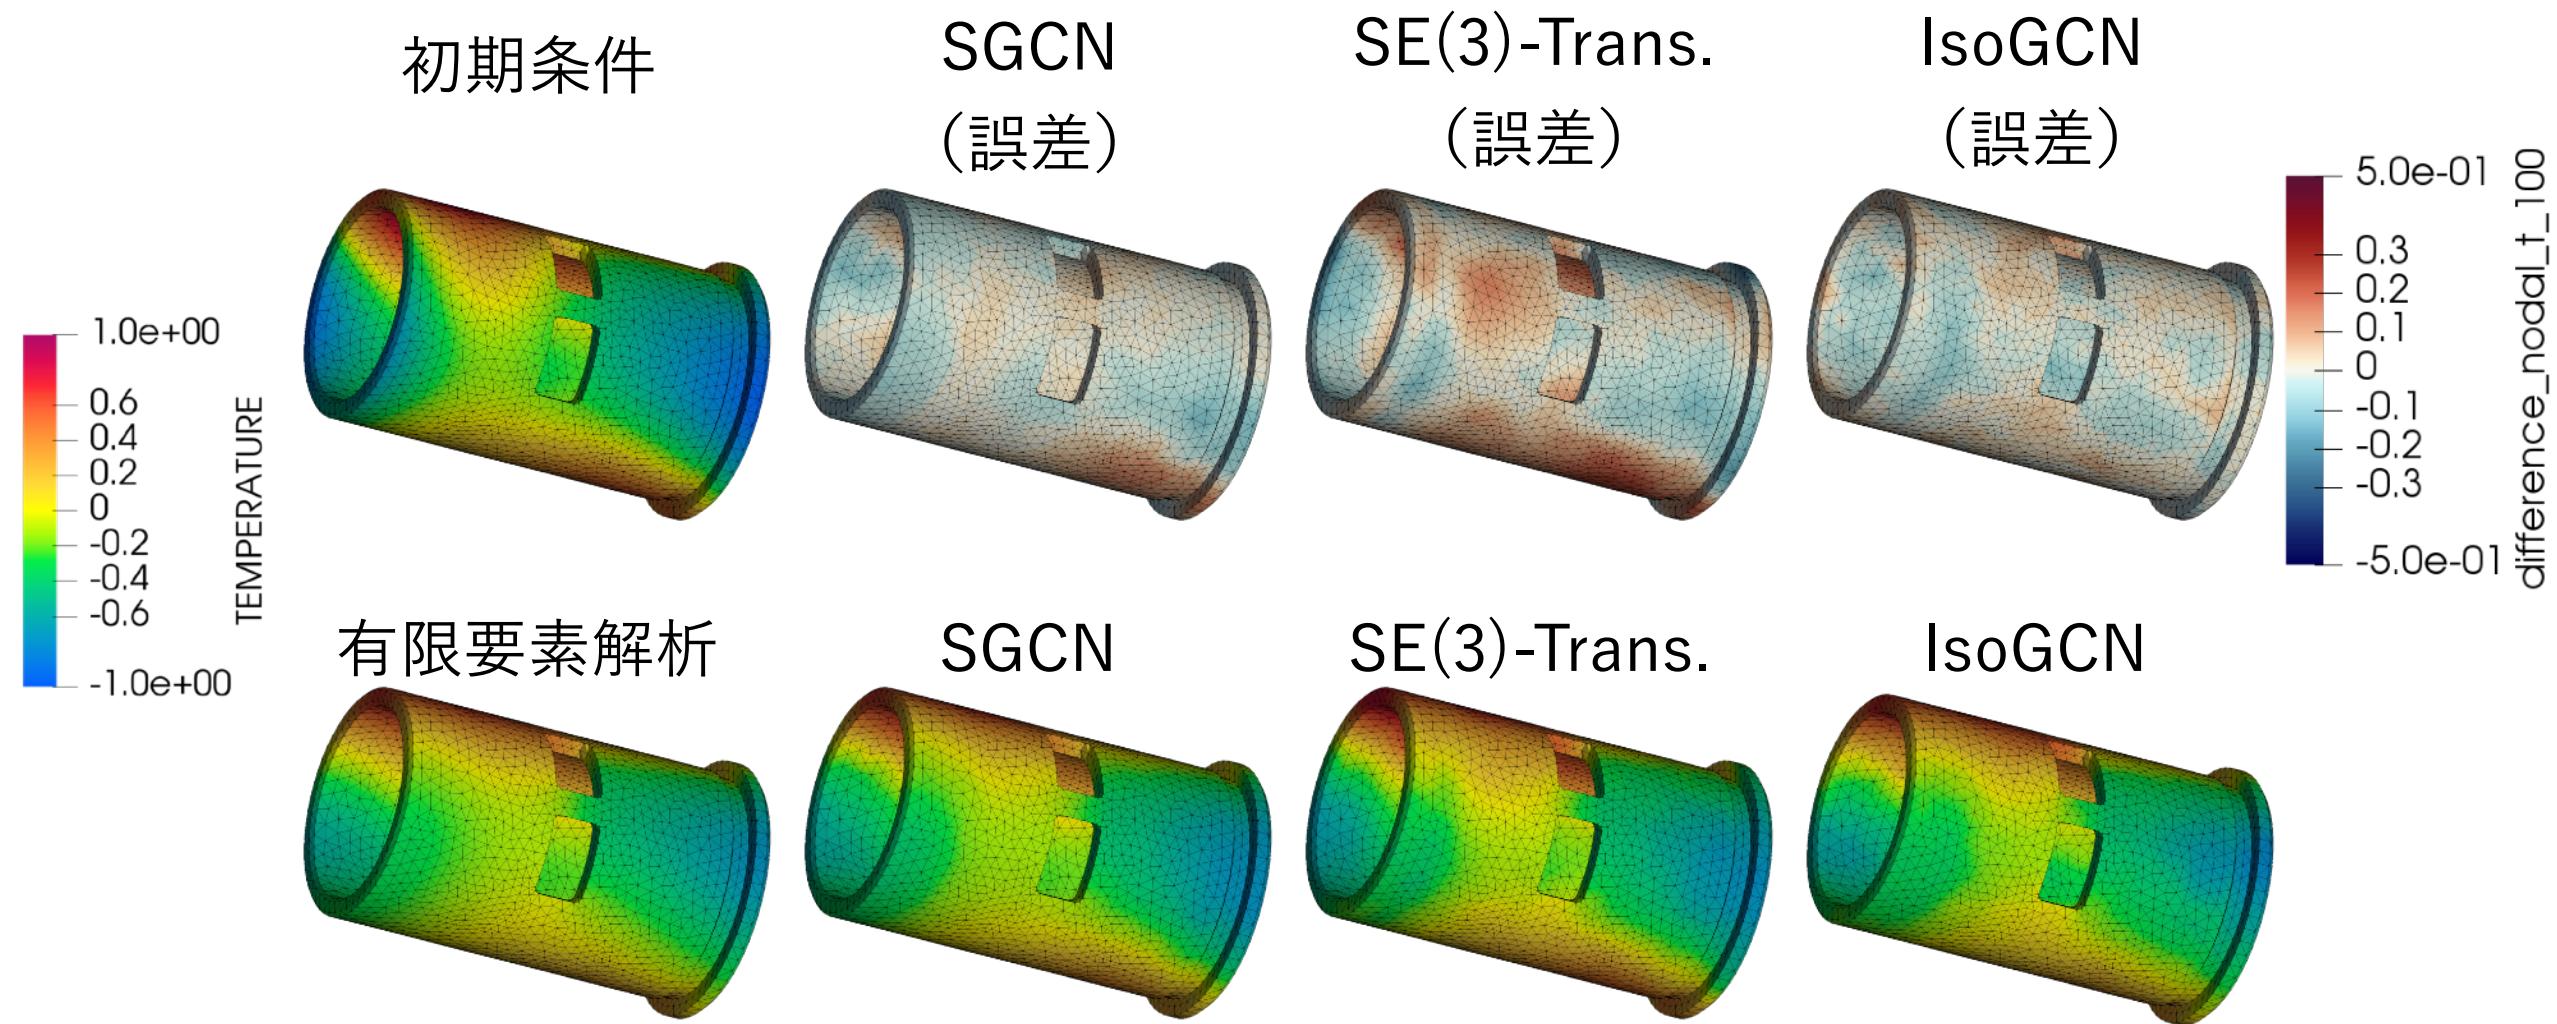
- ABC dataset (Koch+ 2018) から CAD データを抽出
- CAD 形状ひとつにつきメッシュサイズ 3 通り  
初期条件 3 通りの最大 9 サンプルを生成
  - Training dataset: 50 形状、439 サンプル
  - Validation dataset: 16 形状、143 サンプル
  - Test dataset: 16 shapes、140 サンプル

# 実験：非定常・異方的・非線型熱拡散問題

初期条件

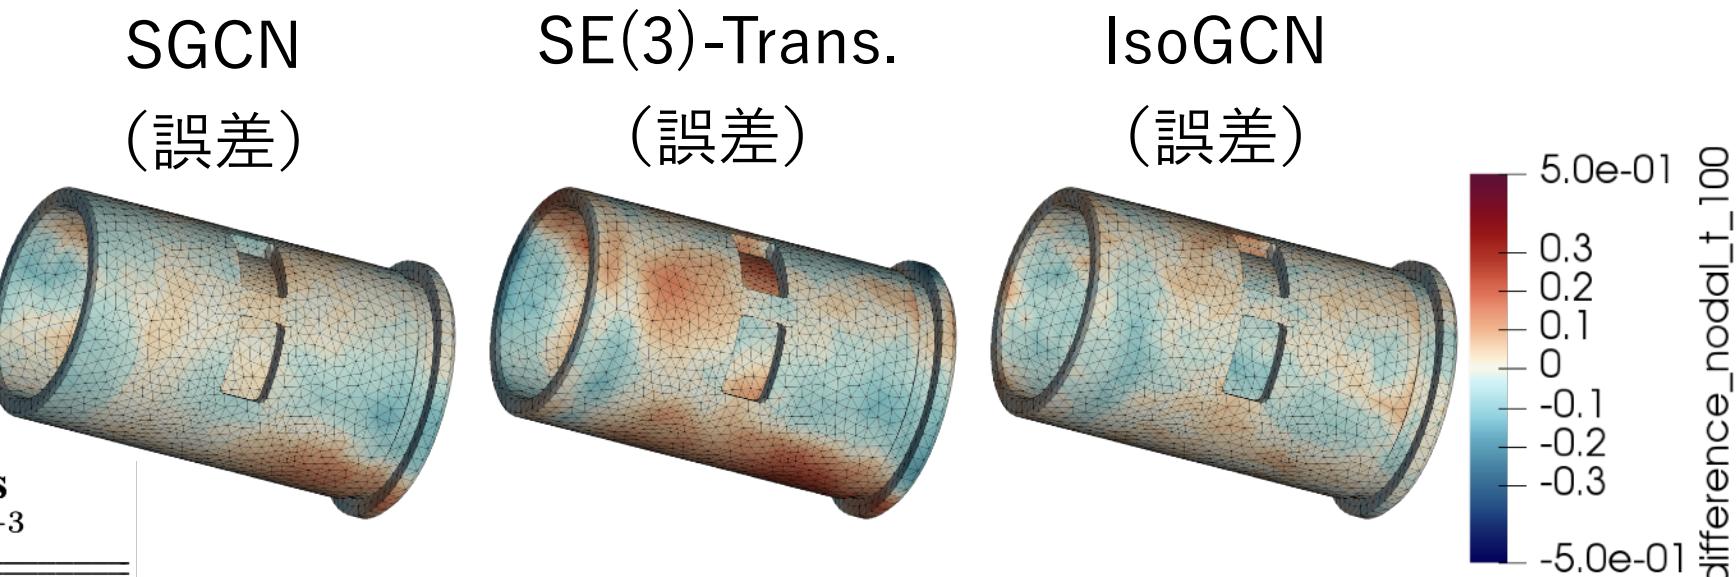


# 実験：非定常・異方的・非線型熱拡散問題



# 実験：非定常・異方的・非線型熱拡散問題

Method	# hops	$x$	Loss $\times 10^{-3}$
GIN	2	No	$16.921 \pm 0.040$
GCN	2	No	$10.427 \pm 0.028$
GCNII	5	No	$8.377 \pm 0.024$
Gluster-GCN	2	No	$7.266 \pm 0.021$
SGCN	5	No	$6.426 \pm 0.018$
TFN	2	No	$15.661 \pm 0.019$
	5	No	OOM
SE(3)-Trans.	2	No	$14.164 \pm 0.018$
	5	No	OOM
IsoGCN (Ours)	2	No	$4.674 \pm 0.014$
	5	No	<b>2.470 ± 0.008</b>



- IsoGCN は既存手法と比較して高精度
- ただし、TFN と SE(3)-Transformer はメモリに載せるためにパラメータ数を少なくしている

# 実験：非定常・異方的・非線型熱拡散問題

- IsoGCN は同等の精度となるセッティングの FrontISTR と比較して高速
- TFN・SE(3)-Transformer は大規模メッシュでは Out-of-Memory (500 GB)

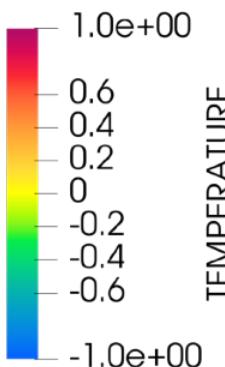
Method	$ \mathcal{V}  = 21,289$		$ \mathcal{V}  = 155,019$		$ \mathcal{V}  = 1,011,301$	
	Loss $\times 10^{-4}$	Time [s]	Loss $\times 10^{-4}$	Time [s]	Loss $\times 10^{-4}$	Time [s]
FrontISTR ( $\Delta t = 1.0$ )	10.9	16.7	6.1	181.7	2.9	1656.5
FrontISTR ( $\Delta t = 0.5$ )	0.8	30.5	0.4	288.0	0.2	2884.2
TFN	77.9	46.1	30.1	400.9	OOM	OOM
SE(3)-Transformer	111.4	31.2	80.3	271.1	OOM	OOM
<b>IsoGCN (Ours)</b>	<b>8.1</b>	<b>7.4</b>	<b>4.9</b>	<b>84.1</b>	<b>3.9</b>	<b>648.4</b>

# 実験：非定常・異方的・非線型熱拡散問題

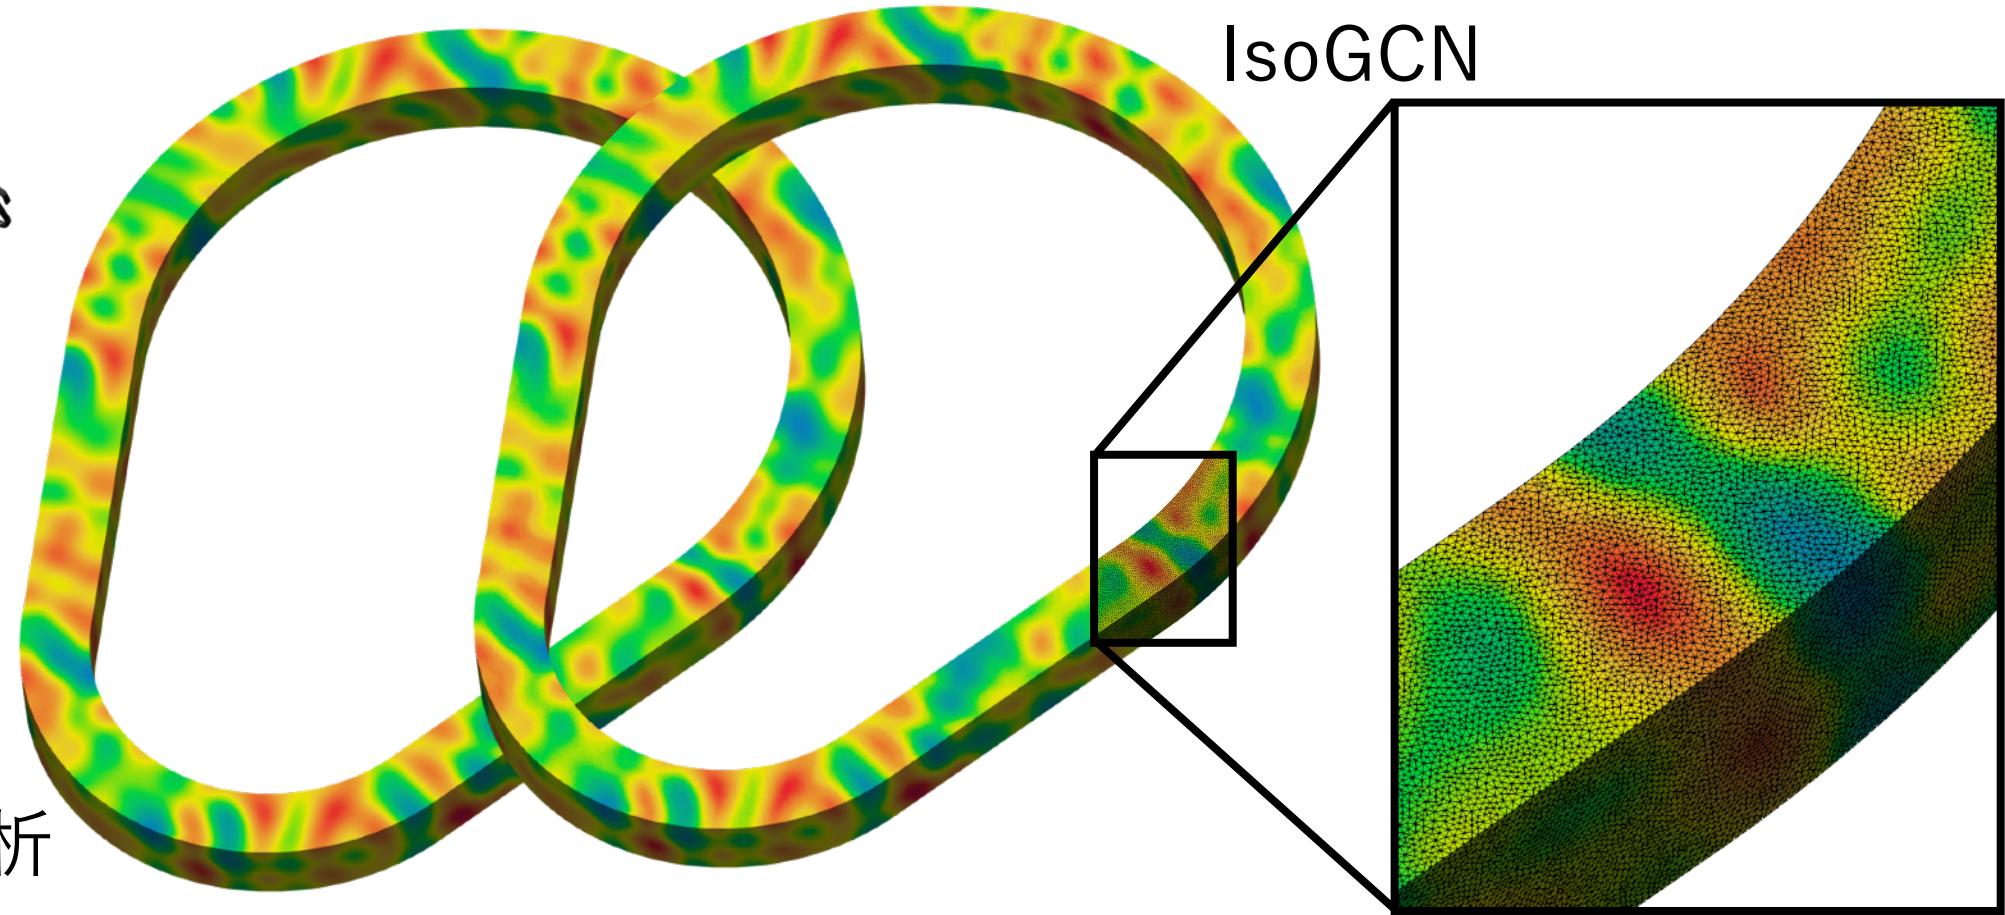
- 学習データサンプルより大きなメッシュに対しても外挿可能

学習データ

サンプル  $s$



有限要素解析



# 目次

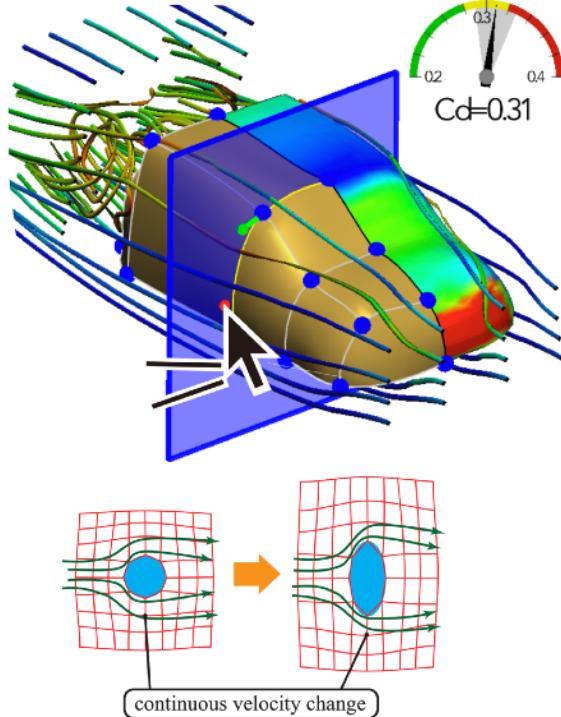
- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

# 目次

- Graph neural network
- 同変性
- IsoGCN: 同変性 + Graph Neural Network
- まとめ

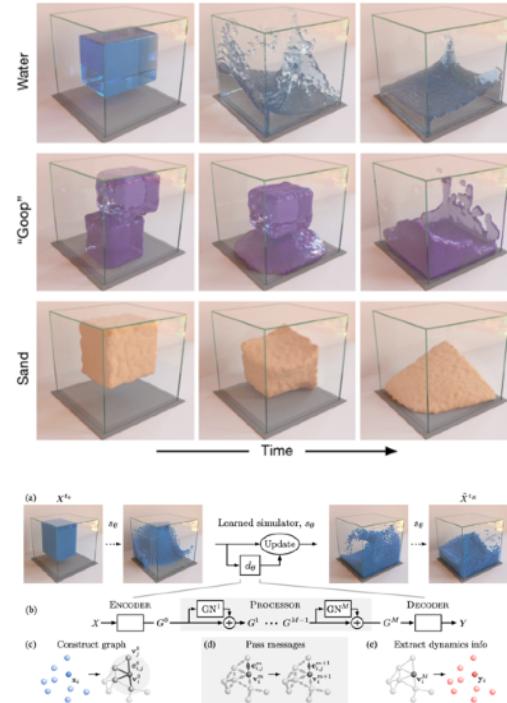
# 関連研究：物理シミュレーションの機械学習

→ Graph Neural Network の適用



Umetani+ 2018

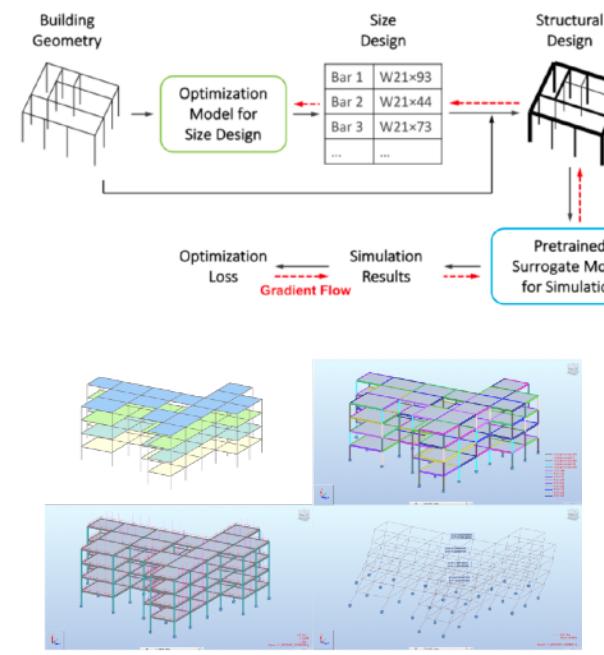
- リアルタイムで車体の空力性能予測
- メッシュ構造固定



Sanchez-Gonzalez+ 2020

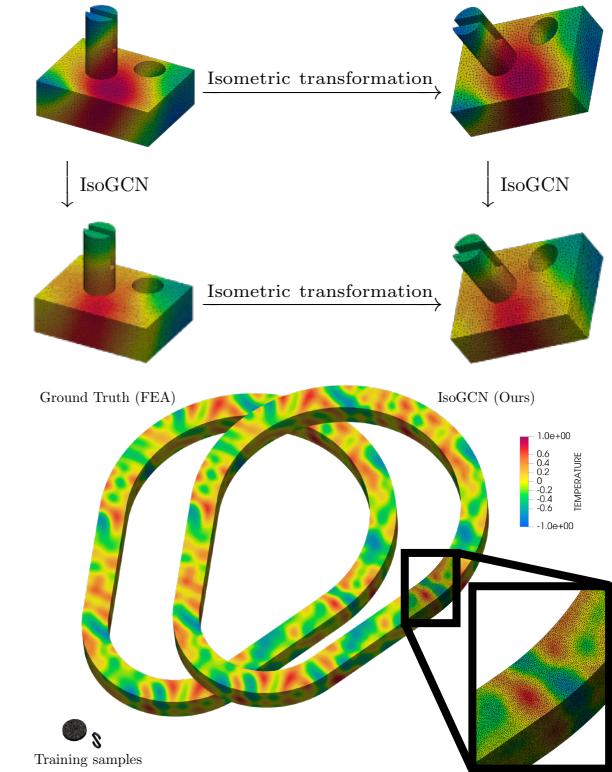
- 任意点群での学習
- 高速化は未達成

→ 同変性の導入



Chang+ 2020

- 任意梁構造での学習
- 梁部材選定の最適化

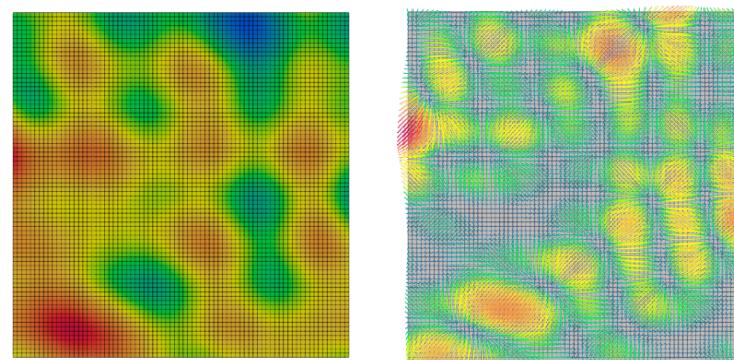


Horie+ 2020

- 任意メッシュでの学習
- 高速化を達成
- 物理現象の対称性を考慮

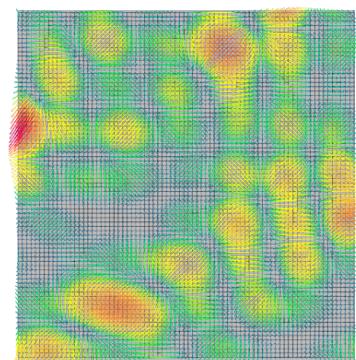
# 概要：対称性があり計算効率のよい GNN を開発

- IsoGCN: 合同変換不变・同変で計算効率のよい GNN (Horie+ 2020)
- IsoGCN は同等の精度の有限要素解析より高速
- IsoGCN は微分演算子の近似とみなせる

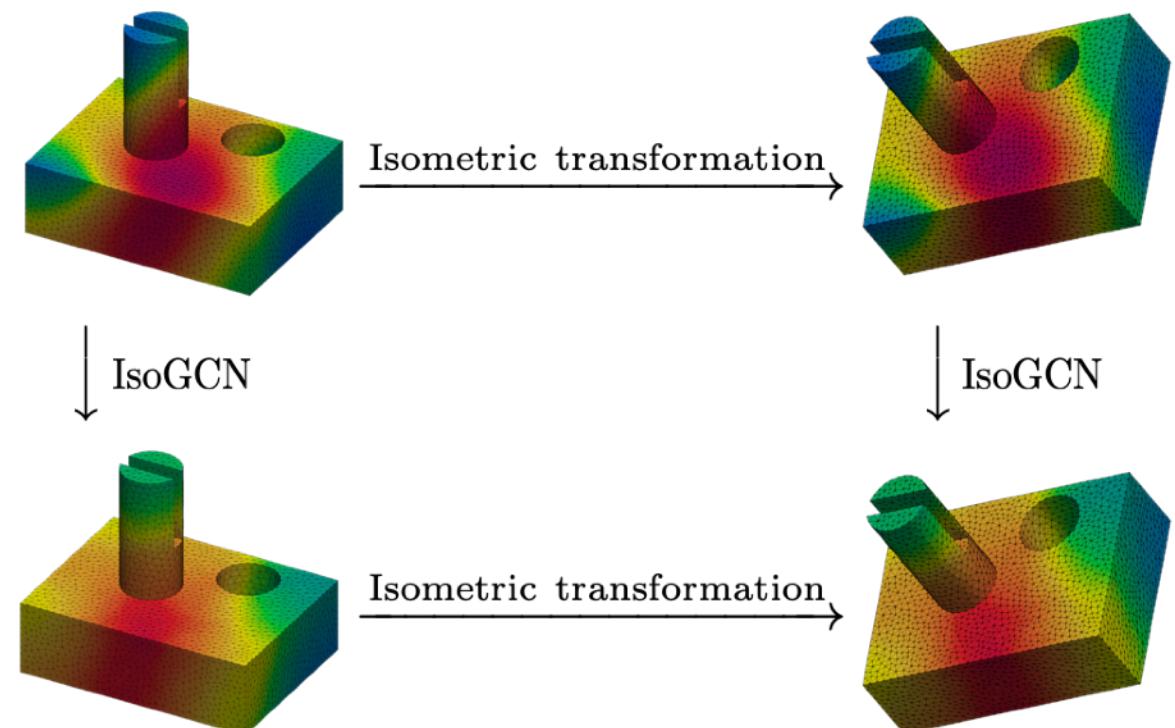


スカラー場  
(入力)

勾配  
(正解)



勾配  
(推論)

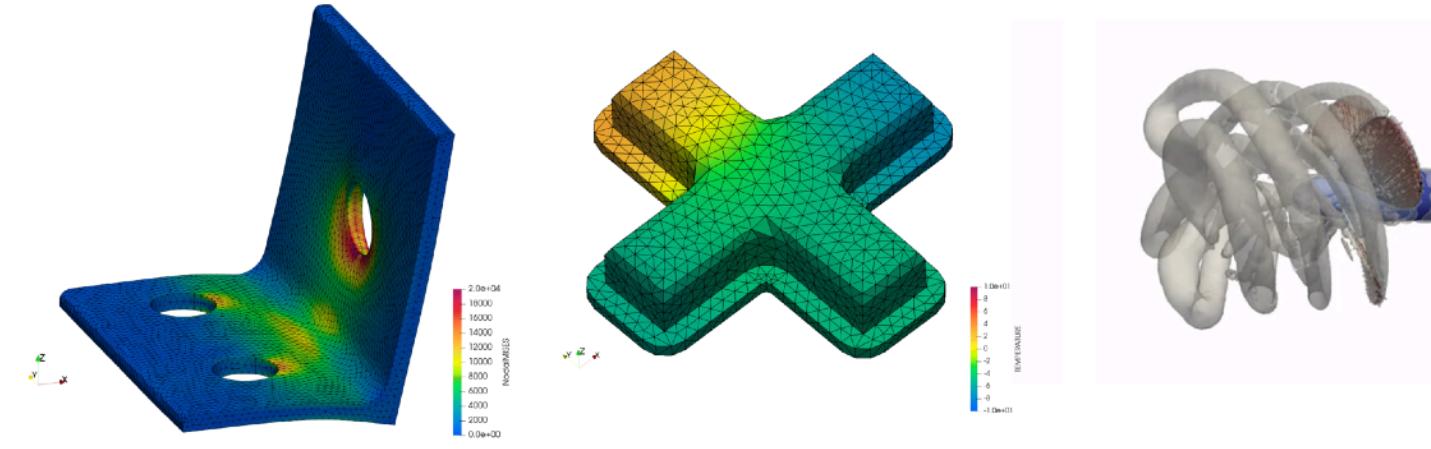


# 概要：対称性があり計算効率のよい GNN を開発

- IsoGCN: 合同変換不变・同変で計算効率のよい GNN (Horie+ 2020)
- IsoGCN は同等の精度の有限要素解析より高速
- IsoGCN は微分演算子の近似とみなせる

今後の展望：

- IsoGCN の近似性能を評価
- IsoGCN を多様な物理現象へ適用



# References

- N. Umetani, and B. Bickel. Learning three-dimensional flow for interactive aerodynamic design. ACM Transactions on Graphics (TOG) 37.4: 1-10, 2018.
- A. Sanchez-Gonzalez, J. Godwin, T. Pfaff, R. Ying, J. Leskovec, and P. W. Battaglia. Learning to simulate complex physics with graph networks. In ICML, 2020.
- K. Chang and C. Cheng. Learning to simulate and design for structural engineering. In ICML, 2020.
- M. Horie, N. Morita, T. Hishinuma, Y. Ihara, and N. Mitsume. Isometric Transformation Invariant and Equivariant Graph Convolutional Networks. arXiv preprint arXiv:2005.06316, 2020.
- E. Ahmed, A. Saint, A. E. R. Shabayek, K. Cherenkova, R. Das, G. Gusev, D. Aouada and B. Ottersten. Deep Learning Advances on Different 3D Data Representations: A Survey. arXiv preprint arXiv:1808.01462, 2018.
- T. N. Kipf, and M. Welling. Semi-supervised classification with graph convolutional networks. In ICLR, 2017.
- N. Thomas, T. Smidt, S. Kearnes, L. Yang, L. Li, K. Kohlhoff, and P. Riley. Tensor field networks: Rotation-and translation-equivariant neural networks for 3d point clouds. arXiv preprint arXiv:1802.08219, 2018.
- N. Dym, and H. Maron. On the Universality of Rotation Equivariant Point Cloud Networks. arXiv preprint arXiv:2010.02449, 2020.
- T. Tamai and S. Koshizuka. Least squares moving particle semi-implicit method. Computational Particle Mechanics, 1(3):277–305, 2014.
- S. Koch, A. Matveev, Z. Jiang, F. Williams, A. Artemov, E. Burnaev, M. Alexa, D. Zorin, and D. Panozzo. Abc: A big cad model dataset for geometric deep learning. In The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 2019.