

AI for Physics

シミュレーションベース機械学習

理化学研究所 革新知能統合研究センター 副センター長
防災科学チームリーダー

(兼務) NTTコミュニケーション科学基礎研究所 客員フェロー

JST CREST (数理情報基盤) 研究総括
ムーンショット目標3 (AI x ロボティクス) AI担当SPD

上田 修功

問題意識

① モデルベースアプローチ（従来のサイエンス研究）

第一原理計算によるシミュレーション(演繹的推論)

② データ駆動アプローチ（現状の機械学習研究）

膨大なデータからの帰納的学習

(レッドオーシャン！ ; Googleの圧勝)



いずれにおいても、**限られたデータの壁**、**内挿的予測の限界**を打破できていない！（現状ではブルーオーシャン！）

AI for Science (世界の動向)



Microsoft

<https://www.microsoft.com/en-us/research/blog/ai4science-to-empower-the-fifth-paradigm-of-scientific-discovery/>

https://ledge.ai/articles/intel_aurora-genai

Intel : 1兆パラメータの科学指向AI「Aurora gen AI」

Accelerating Extreme Weather Prediction with FourCastNet

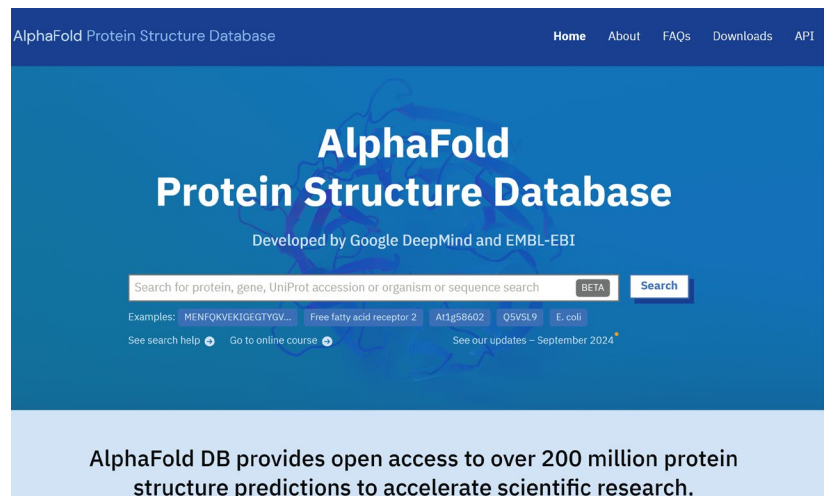
YouTube · NVIDIA · 2022/03/23

YouTube



https://www.youtube.com/watch?v=nuT_U1AQz3g

NVIDIA : 気象予測「FourCastNet」



<https://alphafold.ebi.ac.uk/>

Google DeepMind & EMBL-EBI: タンパク質構造予測「AlphaFold」

AI for Science at RIKEN

TRIP: Transformative Research Innovation Platform of RIKEN Platforms



最先端研究プラットフォーム連携（TRIP）事業本部は、理研の最先端研究プラットフォーム群（スーパーコンピュータ「富岳」、量子コンピュータ、大型放射光施設SPring-8、バイオリソース事業など）をつなぎ、「良質なデータ整備」「AI×数理」「計算可能領域の拡張」による研究DXの先駆的な研究基盤を機能させるとともに、これらを活用した新たな価値創生に資する研究を推進します。

TOP ABOUT TRIP RESEARCH NEWS

MESSAGE CONTACT **ENGLISH**

TRIP 1

良質なデータ整備
(蓄積・統合)

拡張した計算基盤による解析に向けた良質なデータ取得と多様なデータの蓄積・統合による解析基盤の整備

READ MORE

TRIP 2

AI×数理
(予測の科学)

数理科学により、スパコン、AI、量子コンピュータをつなぎ、様々な分野における量子HPCハイブリッド計算のアルゴリズム開発を実施

READ MORE

TRIP 3

計算可能領域の拡張
(量子HPCハイブリッド)

量子コンピュータ・スーパーコンピュータを連携させたハイブリッドコンピューティング基盤による計算可能領域の拡張

READ MORE

Use case

新たな価値創生、社会課題解決への貢献

プラットフォームオププラットフォームを活用したユースケースによる新たな価値創生、社会課題解決への貢献

READ MORE

<https://trip.riken.jp/>

Key technologies:

DNN

Transformer

Physics-informed NN

Operator learning

～モデル駆動とデータ駆動の新たな融合～

～ AI for Science ～


- シミュレーションを深層学習で代替
- 物理法則に忠実な深層学習の実現
- 複雑な数理モデルを深層学習で解く

シミュレーションを 深層学習で代替

シミュレーションの高速化

地震動予測


3D地盤モデル



3D分布

- V_P : P-wave speed
- V_S : S-wave speed
- ρ : mass density

地震動シミュレーション



FEM IIによる大規模シミュレーション

$$V_P^2 \Delta \phi \quad \phi = \nabla \cdot \mathbf{u}$$

$$\dot{\psi} = V_S^2 \Delta \psi \quad \psi = \nabla \times \mathbf{u}$$

地震被害推定



建物、インフラ被害
予測

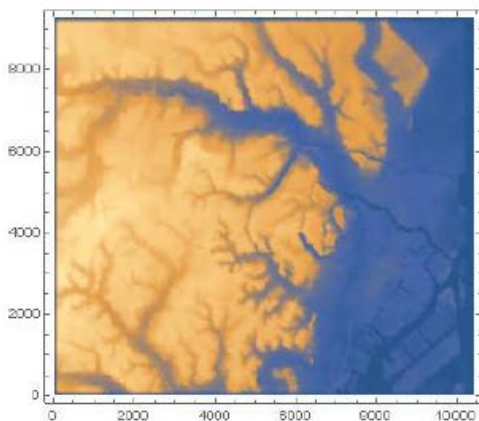
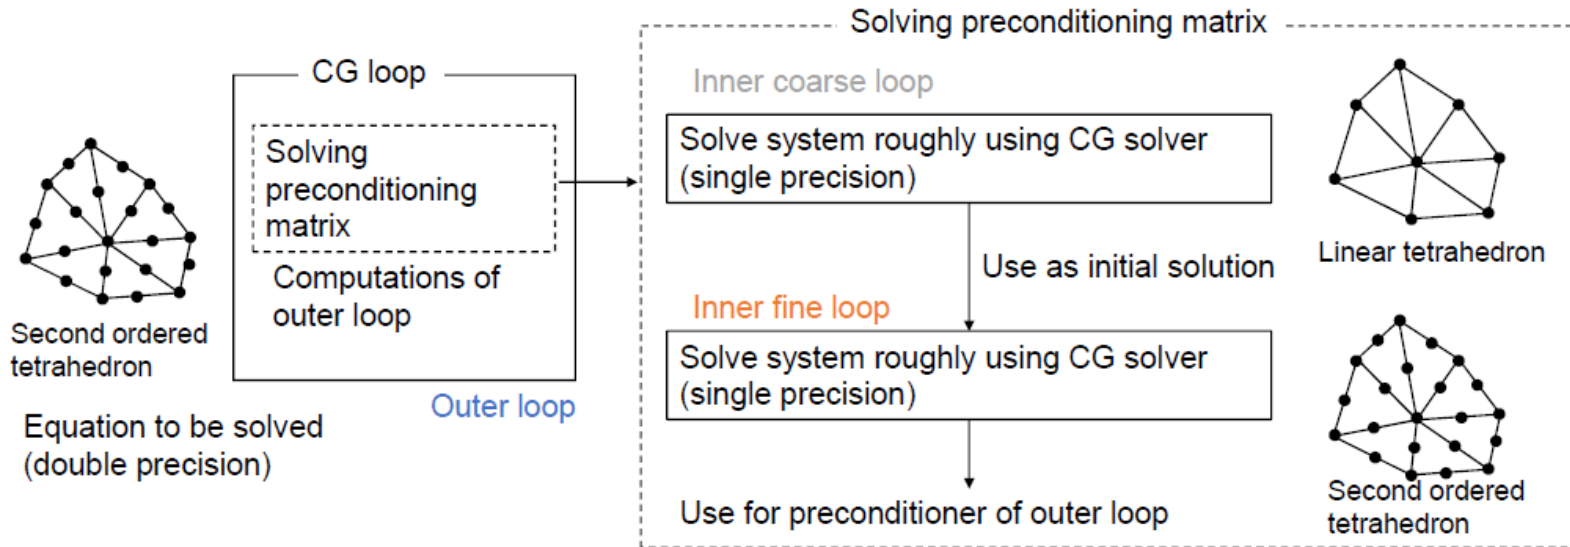
メッシュ間隔
<100 m

HPC上での物理シミュレーション


HPC手法の開発

SC15 ゴードンベル賞ファイナリスト^{ref6)}


市村(東大)



地表面標高

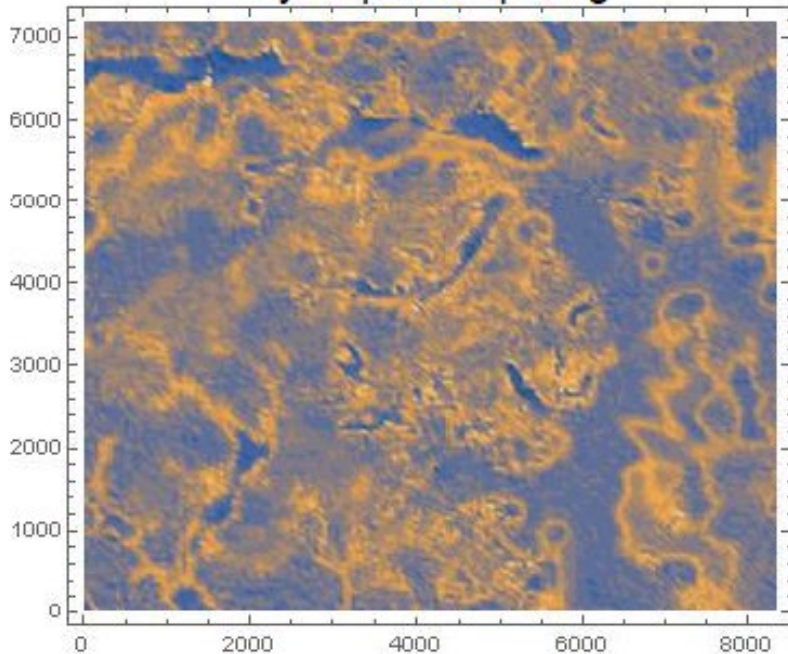


1層目と2層目の層境標高




2層目と3層目の層境標高

By Supercomputing



By AI with Super-computed data



	Training data	Test data	Check data	Total
# of samples	22360	1000	1000	24360
Case A	19929 (89.1%)	880 (88.0%)	891 (89.1%)	21700 (89.1%)
Case B	22219 (99.4%)	992 (99.2%)	994 (99.4%)	24205 (99.4%)

**SC2017
Best Poster
Award**


The number of correct answers and correct ratios. Judged correct if $|\text{target value} - \text{estimated value}| < 2$

1000 points are picked up from 23,460 points as test data and check data.

超並列計算物理シミュレーションと データ学習のハイブリッド手法

富岳全系（7,312,896並列）までスケールする超並列計算物理シミュレーションとデータ学習のハイブリッド手法を開発し、**世界初の断層-都市超高詳細解析を実現**

- 地震シミュレーションの根幹となる非構造低次有限要素法によるテラ自由度級大規模非線形動的解析。地震の被害想定・メカニズム解明への貢献が期待される
- 富岳全系までスケールするデータ学習により物理シミュレーションを高速化する手法を開発
- この規模・性能の地震シミュレーションは日本でのみ実現。
- 京コンピュータ比1,070倍の性能向上



地震による津波浸水被害のリアルタイム予測

Machine Learning-based Tsunami Inundation Prediction Derived from Offshore Observations

Iyan E. Mulia^{1,2}, Naonori Ueda^{1,2}, Takemasa Miyoshi^{1,3}, Aditya Riadi Gusman⁴, Kenji Satake⁵

¹Prediction Science Laboratory, RIKEN Cluster for Pioneering Research, Kobe, Japan.

²Disaster Resilience Science Team, RIKEN Center for Advanced Intelligence Project, Tokyo, Japan.

³Data Assimilation Research Team, RIKEN Center for Computational Science, Kobe, Japan.

⁴GNS Science, Lower Hutt, New Zealand.

⁵Earthquake Research Institute, The University of Tokyo, Tokyo, Japan.

Nature Communications. 2022.

日本海溝海底地震津波観測網：S-net

観測網の全体概要

地震計と水圧計が一体となった観測装置を海底ケーブルで接続し、これを日本海溝から千島海溝海域に至る東日本太平洋沖に設置し、リアルタイムに24時間連続で観測データを取得します。観測装置は150カ所に設置し、ケーブル全長は約5,500kmになります。

海溝型地震や直後の津波を直接的に検知し、迅速かつ確実な情報伝達により被害の軽減や避難行動などの防災対策に貢献することが期待されます。海域の地震像の解明のためにも海底における観測データは必要不可欠です。平成28年度より①房総沖から⑤釧路・青森沖の5つの海域において運用を開始し、平成29年4月から⑥海溝軸外側（アウターライズ）を含めたすべての海域において運用を行っております。

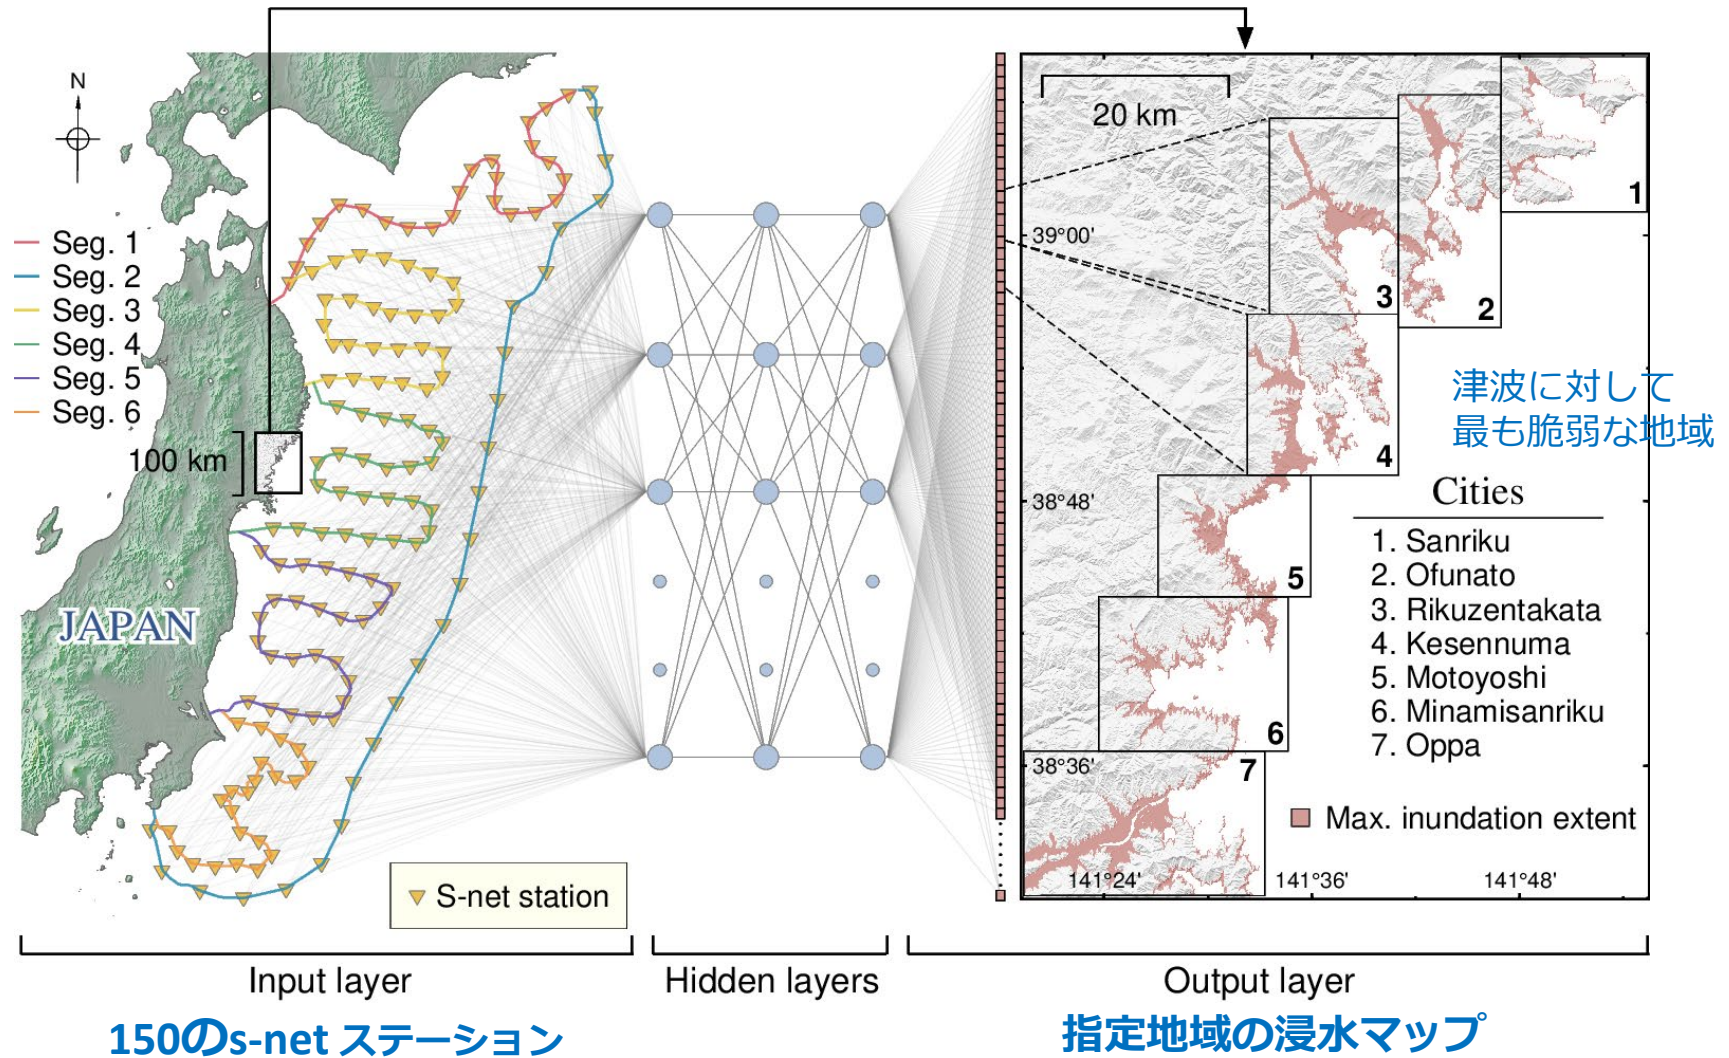
観測網は次の5つの海域と日本海溝の外側にそれぞれ設置します。

- ① 房総沖
- ② 茨城・福島沖
- ③ 宮城・岩手沖
- ④ 三陸沖北部

観測網の構成



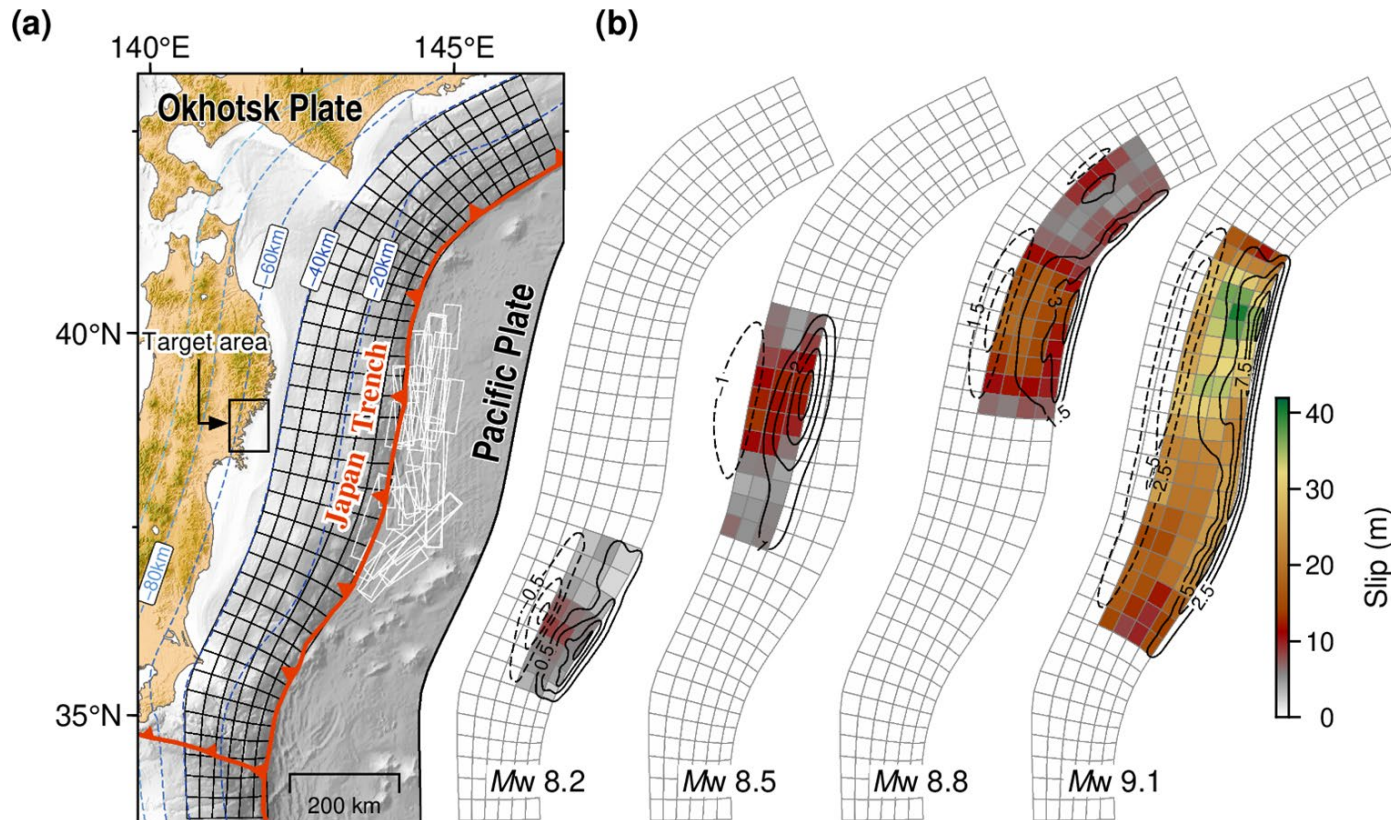
海域の観測無しに、S-net を入力として、指定地域の浸水マップを出力する機械学習技術を提案



S-net: 日本海溝に沿って地震と津波のための海底観測ネットワーク (S-net) 。 14
1 kHz の高周波データをリアルタイムで送信できる海底圧力センサーと地震計で構成

地震発生シナリオ

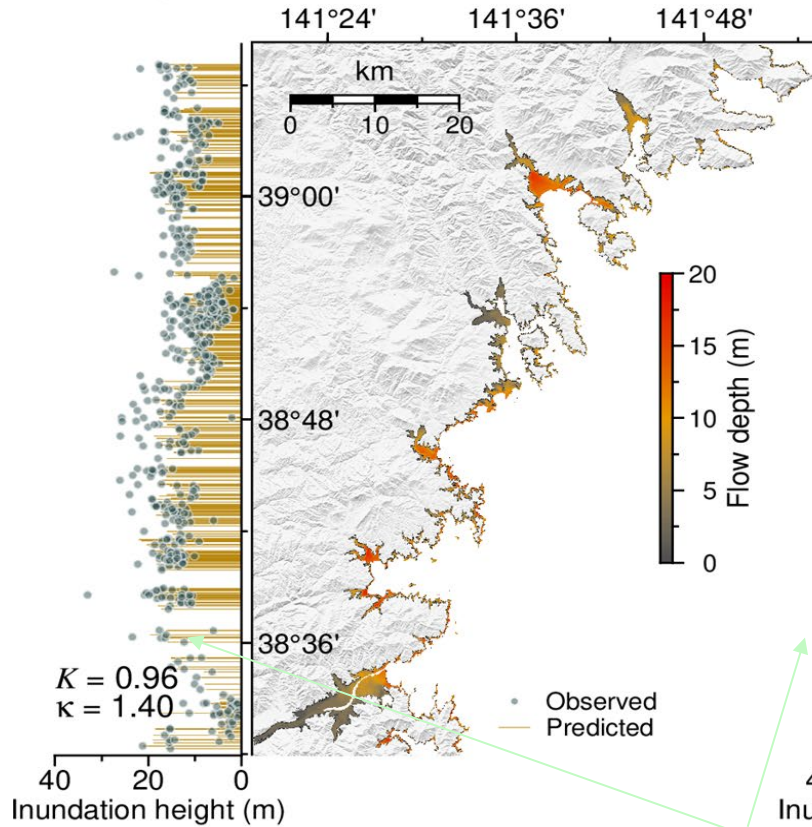
- Mw 8.0~9.1 (0.1間隔) の仮想のメガスラスト地震を多数生成し、スリップを補間して曲面パッチに投影する。
- 非線形浅水波方程式を数値的に解くことにより津波の伝搬を算出。
- 曲面パッチ (グリッド) での値 (最大水面高度) をS-netのセグメントの値に変換。



メガスラスト断層 (地震の沈下と隆起を表す)

物理シミュレーション


(a) Physics-based model



Computing time = ~30 min

提案法

(b) Machine learning-based model



Computing time = 0.05 sec

同等な予測精度をリアルタイムで実現！

物理法則に忠実な 深層学習の実現

～ AI for Science ～

研究動向

DNNでODEを解く

ベクトル場 $f(x; \theta)$ を
直接NN等で学習

- **Neural ODE** [Chen+'18]
 - DiffGP [Hegde+'19]
- など

偏微分方程式を NNで解く

- PDEと初期・境界条件
を与えてNNで学習
- **PINN**[Raiss+'19]など

物理法則を満たしつつ データからモデルを獲得

保存量（エネルギー等）
という構造を仮定
（保存系）

- **HNN** [Greydanus+'19]
 - LNN [Cranmer+'20]
 - SympGPR [Rath+'21]
- など

エネルギーの減衰という
知識を仮定
（散逸系）

- **DGNet** [Matsubara+'20]
 - GHNN [Course+'20]
- など

データから解作用素を学習

初期条件とその場合のPDEの解の組
のデータから背後にあるPDEを推定
Neural Operator[Li+'20]など

Neural Ordinary Differential Equation (NODE)

Residual NN (**RESNet**: He et al., NeurIPS2015)

Chen et al., NeurIPS2018

skip connection の導入

Traditional Deep Nets


$$\begin{aligned}h_1 &= f_1(x) \\h_2 &= f_2(h_1) \\h_3 &= f_3(h_2) \\h_4 &= f_4(h_3) \\y &= f_5(h_4)\end{aligned}$$

ResNets

$$\begin{aligned}h_1 &= f_1(x) + x \\h_2 &= f_2(h_1) + h_1 \\h_3 &= f_3(h_2) + h_2 \\h_4 &= f_4(h_3) + h_3 \\y &= f_5(h_4) + h_4\end{aligned}$$

$$h_N = f(\theta, h_{N-1}) + h_{N-1}$$

Residual Network



連続(時間)隠れ層への拡張: NODE

共通の関数 f をDNNで代替: $\frac{dh(t)}{dt} = f(h(t), t, \theta)$


ODEの解 $z(t_1)$ を入力とした損失関数

$$\begin{aligned}L(z(t_1)) &= L\left(z(t_0) + \int_{t_0}^{t_1} f(z(t), t, \theta) dt\right) \\&= L(\text{ODESolve}(z(t_0), f, t_0, t_1, \theta))\end{aligned}$$


NNの順伝搬+オイラー法

Lの θ に関する微分: アドジョイント法によりメモリーの効率化を図っている


ODE Network



時系列データの学習例



(a) Recurrent Neural Network



(b) Latent Neural Ordinary Differential Equation

緑の点が時系列データを欠損あり&不等間隔にした観測値、青の線がモデルがフィットした線、赤の線が予測値

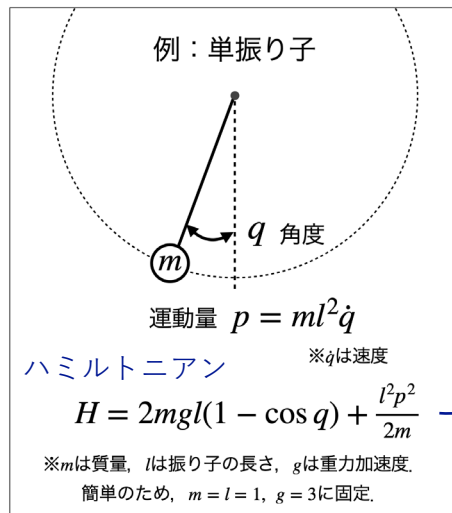
Chen et al., NeurIPS2018

ハミルトニアンNN

ハミルトン力学系を仮定し, エネルギー保存のような「保存則」を満たすようにDNNを学習 [1,2]

ハミルトン力学とは

位置 q と運動量 p で決まる関数 H (ハミルトニアン) が与えられると, ハミルトンの運動方程式を通じてダイナミクスを知ることができる



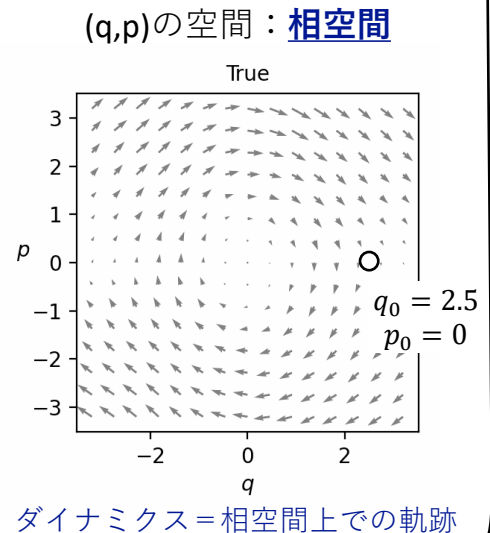
ハミルトンの
運動方程式

$$\dot{q} = \frac{\partial H}{\partial p}$$

$$\dot{p} = -\frac{\partial H}{\partial q}$$

(q,p) の動きを決める
ベクトル場

+ (q_0, p_0)
初期値



[1]Samuel Greydanus et al., Hamiltonian Neural Networks, NeurIPS, 2019.

[2]Takashi Matsubara et al., Deep Energy-Based Modeling of Discrete-Time Physics, NeurIPS, 2020.

ResNet, HNN, DGNet, SSGP

ResNet(2015) $\rightarrow \frac{d\vec{u}}{dt} = f(u) \rightarrow f(u(t), t, \theta)$ **NODE**
(NeurIPS2018)
 $U_t = F(u_{t-1}) + u_{t-1}$ NNで代替
 $\vec{u} \in \mathbb{R}^N$: 状態ベクトル

物理則（エネルギー保存則など）は満たされない



状態ベクトルに関する
エネルギー勾配

$$f(u) = G \nabla H(\vec{u})$$

ハミルトニアン
をNNで代替

$G \in \mathbb{R}^N \times \mathbb{R}^N$ システム行列
 $H : \mathbb{R}^N \rightarrow \mathbb{R}$ エネルギー関数
(ハミルトニアン)

Gが歪対称 : ハミルトン方程式
Hamiltonian NN (NeurIPS2019)
エネルギーを保存

Deep energy NN (NeurIPS2020)
Matsubara et al.,
保存系, 散逸系に適用可能
離散自動微分の提案

Symplectic Spectrum Gaussian Processes

不完全データからのHNNの学習法

Tanaka et al., (NeurIPS2022)

複雑な数理モデルを 深層学習で解く

～ 数値（離散）解法から連続解法へ～

物理深層学習による地殻変動解析

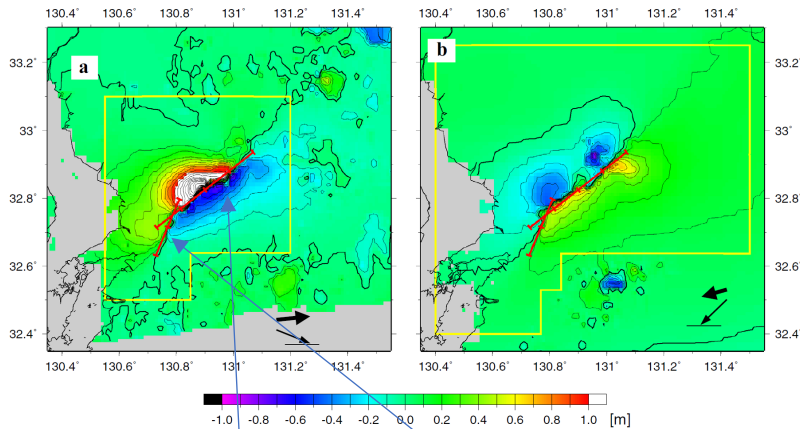
Physics-Informed Deep Learning Approach for Modeling Crustal Deformation

Okazaki, T., Hirahara, T, Ito, T, Ueda, N.

Nature Communications. 2022.

地殻変動のモデリング

観測(人工衛星による地表変位データ)



地表面の変形
(観測)


例. 2016年熊本地震

地殻ダイナミクスの理解

- 地震断層の破壊様式
- プレーートの運動様式
- 地下の弾性・粘性構造

順問題
本研究

逆問題



地下の断層・プレート運動
(モデル)

半世紀以上に亘り、弾性体力学に基づく
解析的・数値的計算手法が発展してきた

本研究 PINNによるモデリングにより変動や
任意の地形・地下構造を連続的に
(離散化せずに) 表現可能



地殻変動をシミュレートする機械学習技術

■ 地殻ダイナミクス(非線形微分方程式)を制約条件とする深層学習技術を考案

例) 布田川断層 (熊本地震, 2016)




視線(z軸)方向




有限要素法
(従来法)

メッシュ毎の
線形近似



提案法
メッシュフリーな
厳密解析



従来手法(上)と本手法(下)における解析領域の表現方法。図は地下構造の断面図
配色は地下を構成する岩石の硬さを表わす

本手法による地殻変動の解析結果。

地下構造の断面図。配色は地震による地殻の変形の計算結果を表す。断層や地形の連続的に曲がった形状や、断層や地下構造の急激な変化によるひずみが解析できている。

地殻変動解析におけるPINNと従来法の比較

	解析的手法	準解析的手法	数値的手法	機械学習手法
代表的手法	グリーン関数	境界積分要素法	有限要素法	PINN(本手法)
微分方程式	線形	線形	○非線形	○非線形
解の表現	○連続的	離散的	離散的	○連続的
断層形状	○畳込み積分	矩形断層の和	矩形断層の和	○曲面断層
地形・不均質	限定的・近似	複雑	○細かいメッシュ	○連続的・自然
逆解析	一様半無限媒質	計算量大	計算量大	○容易
課題	単純な問題設定に限定	複雑な地形・構造のモデル化	高次元・大規模での計算コスト	学習収束までの計算時間

PINNにおける学習

$$f(t, x; w) := u(x, t; w)_t + \mathcal{N}[u(x, t; w)] = 0$$

損失関数: $MSE = MSE_u + MSE_f$, \longrightarrow Minimize w.r.t. w

初期/境界条件:

PDE条件:

← NNのパラメータ

$$MSE_u = \frac{1}{N_u} \sum_{i=1}^{N_u} |u(t_u^i, x_u^i) - u^i|^2,$$

$$MSE_f = \frac{1}{N_f} \sum_{i=1}^{N_f} |f(t_f^i, x_f^i)|^2$$


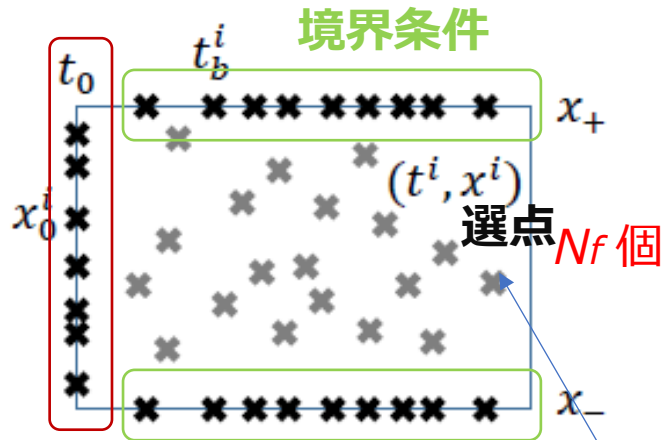
$\{t_u^i, x_u^i, u^i\}_{i=1}^{N_u}$: u に対する学習データ

$\{t_f^i, x_f^i\}_{i=1}^{N_f}$: f に対する学習データ

初期条件, 境界条件, および選点のみから
所与の偏微分方程式を深層学習で解く

NNにより u を推定

初期条件, 境界条件,
物理法則を満たす
ように学習



初期条件
 N_0 個

境界条件
 N_b 個

Note: $u(t, x)$ ではなく, (t, x) としてPDE-lossを
最小化するように学習する

PINNによる横ずれ断層の地殻変動解析


Strike-slip faults

例) 布田川断層 (熊本地震, 2016)



視線(z軸)方向

せん断弾性係数



支配方程式 (横ずれ断層: $u(x, y)$ は z 軸方向で一定)

DS: dislocation surface
FS: free surface

$$\mu \nabla^2 u + \nabla \mu \cdot \nabla u = 0 \text{ in } V \quad \leftarrow v \text{ における微分方程式}$$

$$u^+ - u^- = s \text{ on } \Sigma \quad \leftarrow \Sigma \text{ における境界条件 (s: 既知の変位距離)}$$

$$\sigma^+ \cdot \mathbf{n}^{\text{DS}} = \sigma^- \cdot \mathbf{n}^{\text{DS}} \text{ on } \Sigma \quad \leftarrow \Sigma \text{ における境界条件} \quad \mathbf{n}^{\text{DS}} = (n_x^{\text{DS}}, n_y^{\text{DS}}, 0)$$

$$\sigma \cdot \mathbf{n}^{\text{FS}} = 0 \text{ on } S \quad \leftarrow S \text{ における境界条件} \quad \mathbf{n}^{\text{FS}} = (n_x^{\text{FS}}, n_y^{\text{FS}}, 0)$$


σ : ストレステンソル(3x3行列)

Note: 地殻変動解析では定常状態での解析故、空間微分のための微分方程式となる


PINNの適用における課題と解決法

地震により断層が破壊される(ずれ動く)ため、断層の両側(Σ_+ , Σ_-)で $u(x, y)$ が不連続となり、NNで用いる連続関数では表現不可能

➡ 断層面 Σ に沿ってbranch cutをもつ**極座標表示**を導入

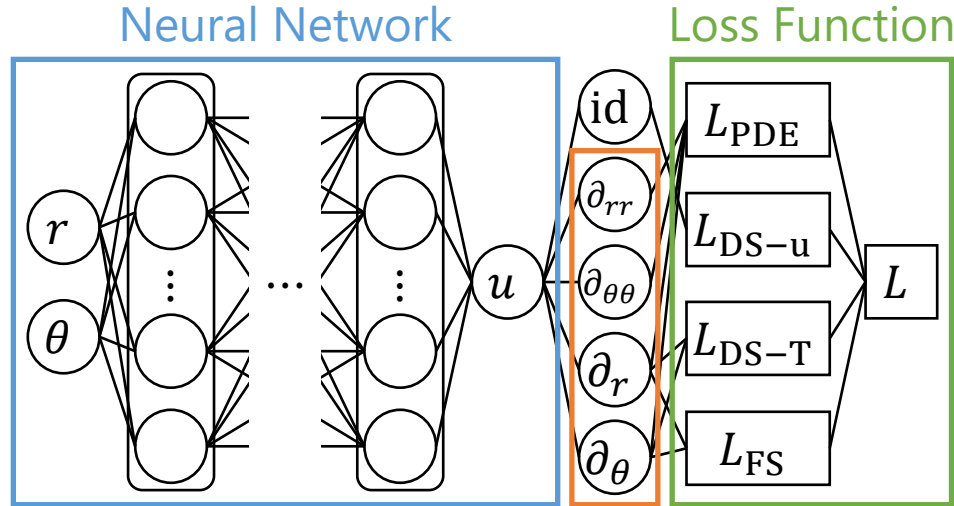


断層の両側で $u(x, y)$ の値が不連続となりPINNの適用は不可



$u(r, \theta)$ は領域全体で連続関数
変位不連続を Σ_+ と Σ_- の境界条件として表現

PINNによる定式化



実験では、8層、40ノード/層のNN **Automatic Differentiation**

損失関数：

$$L = L_{PDE} + L_{DS-u} + L_{DS-T} + L_{FS} \quad \leftarrow \text{微分方程式と境界条件に基づく損失関数}$$

$$L_{PDE} = [r^2 u_{rr} + r u_r + u_{\theta\theta} + \mu^{-1} (r^2 \mu_r u_r + \mu_\theta u_\theta)]^2 \quad \leftarrow v \text{における微分方程式}$$

$$L_{DS-u} = (u^+ - u^- - s)^2 \quad \leftarrow \Sigma \text{における境界条件 (s: 既知の変位距離)}$$

$$L_{DS-T} = r^2 [\mu^+ (n_x^{DS} u_x^+ + n_y^{DS} u_y^+) - \mu^- (n_x^{DS} u_x^- + n_y^{DS} u_y^-)]^2 \quad \leftarrow \Sigma \text{における境界条件}$$

$$L_{FS} = r^2 (n_x^{FS} u_x + n_y^{FS} u_y)^2 \quad \leftarrow s \text{における境界条件}$$

$$u_x = \sin \theta u_r + r^{-1} \cos \theta u_\theta$$

$$u_y = \cos \theta u_r - r^{-1} \sin \theta u_\theta$$



Note: 下付き添え字はその変数での微分を表す

実験結果 (断層が曲線、地表面が曲線、媒質非一様のケース)



解析的に解けないため、
有限要素法(FEM)と比較

タスク

結果

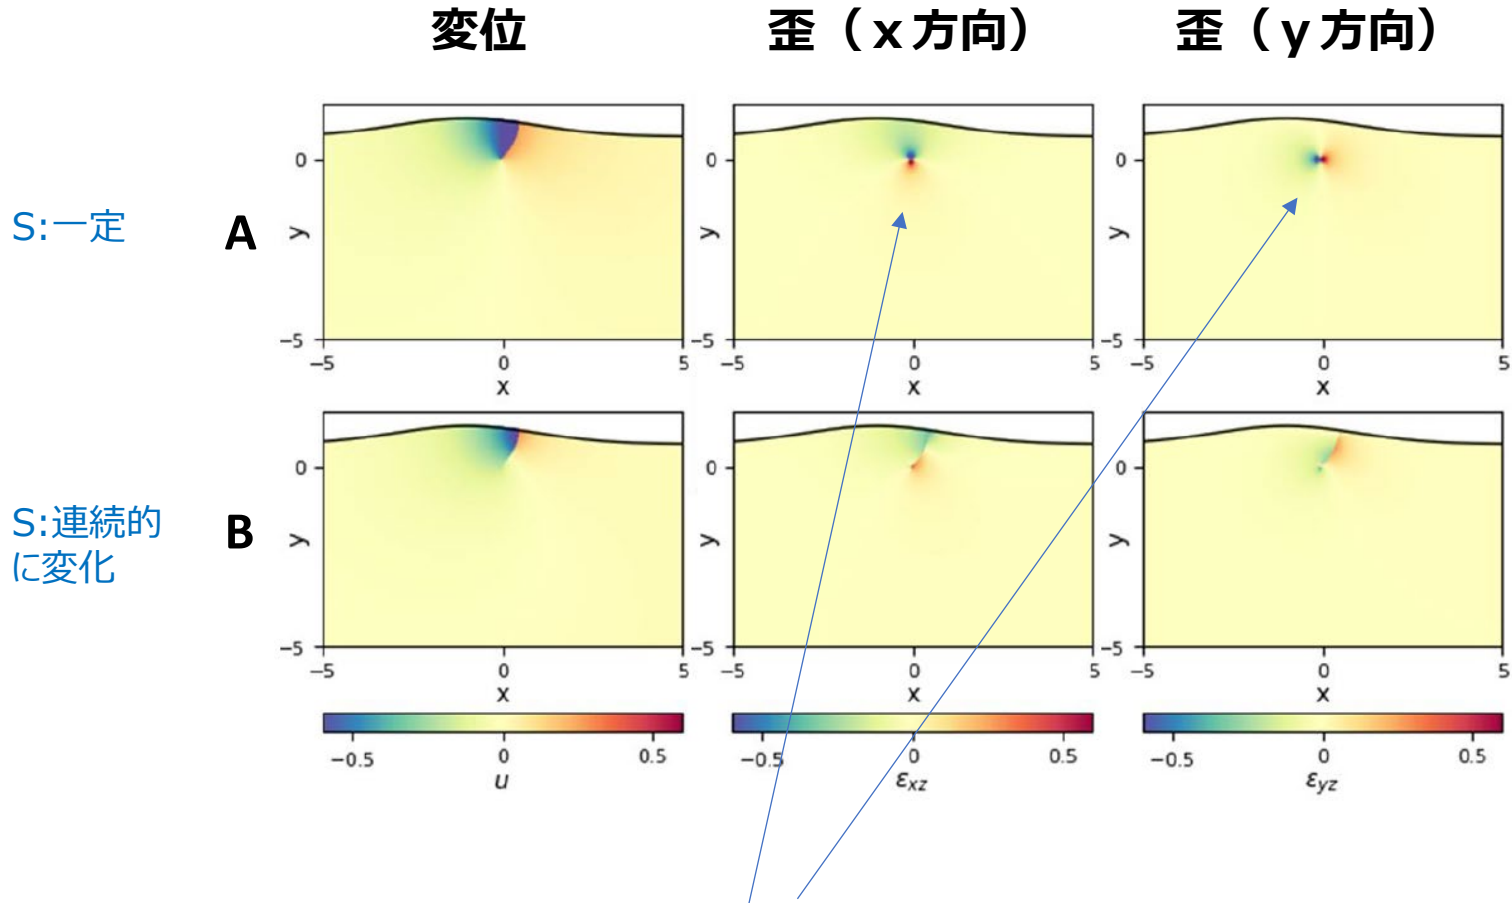


点線 : FEM
実線 : PINN



PINNの結果は、有限要素法 (FEM)と同等

領域内での変位と歪の評価




Note: s が一定の場合、一様すべりが再現されている (既存理論と一致)

作用素学習（解作用素）

パラメトリックPDEの解の学習



数値シミュレーションにより、係数と解とのペアのデータで学習



学習後、任意の係数に対する解は瞬時に出力可能

従来の数値解法では、異なる係数ごとに解きなおしていたが、作用素学習では一括学習が可能。ただし、汎化能力を上げるには、多数の学習データが必要

Neural Operator

GNO: Li+ , arXiv'20

$$\mathcal{G}_\theta := Q \circ \sigma_T(W_{T-1} + \mathcal{K}_{T-1} + b_{T-1}) \circ \dots \circ \sigma_1(W_0 + \mathcal{K}_0 + b_0) \circ \mathcal{P}$$

活性化関数

T層のカーネル積分作用素

バイアス

- $a(x)$ から $u(x)$ への変換をT層のNNでモデル化

$v_t(x)$ は \mathbb{R}^{d_v} 上のrepresentation, $P(\cdot)$ と $Q(\cdot)$ はNN

$$v_0(x) = P(a(x)) \quad \text{Lifting: 次元を上げる}$$

For $t=1, \dots, T$

線形変換

Iterative Kernel Integration

$$v_{t+1}(x) := \sigma \left(W v_t(x) + (\mathcal{K}(a; \phi) v_t)(x) \right)$$

activation

Kernel integral operator

$$u(x) = Q(v_T(x)) \quad \text{Projection} \quad u \text{の次元に戻す}$$

グリーン関数法との関連

$$(\mathcal{L}_a u)(x) = f(x)$$

$$u(x) = \int_D G_a(x, y) f(y) dy$$

グリーン関数G

$f(y)$ を $G(x, y)$ の重みで重ね合わせる

Kernel integral operator

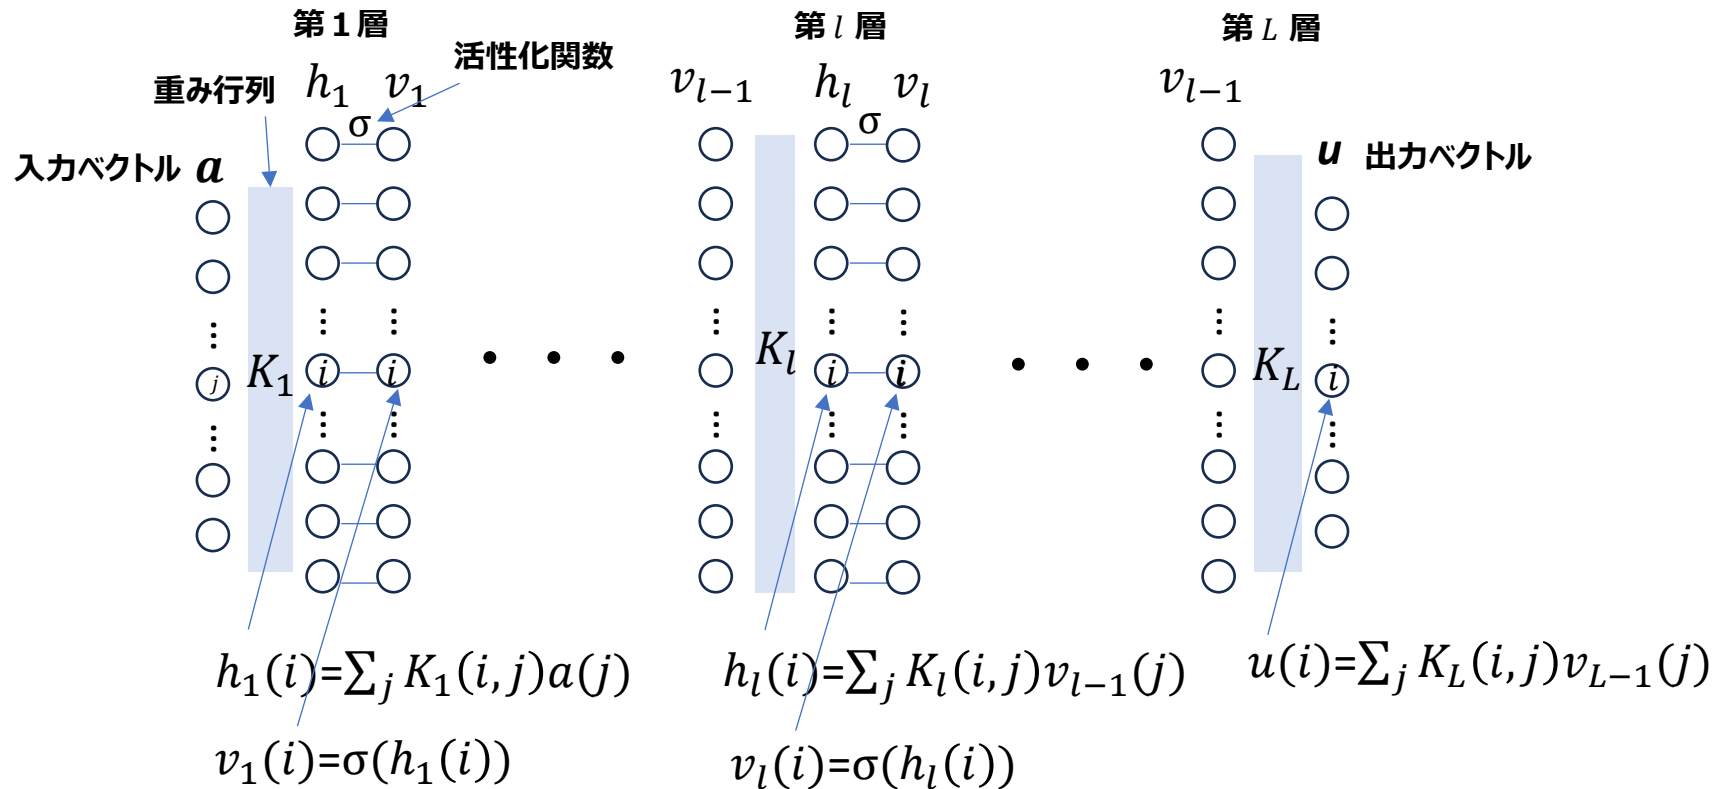
κ は $\mathbb{R}^{d_v \times d_v}$ の出力を持つNN

$$(\mathcal{K}(a; \phi) v_t)(x) := \int_D \kappa(x, y, a(x), a(y); \phi) v_t(y) dy \longrightarrow$$

論文では離散点をグラフと見なして
グラフNNを用いている。Nystrom近似
で効率化 (それでも高コスト)

多層ニューラルネットワーク

通常のDNNは以下のように、積和計算(線形演算)と活性化関数(非線形演算)を繰り返している (簡単のためバイアス項は無視)



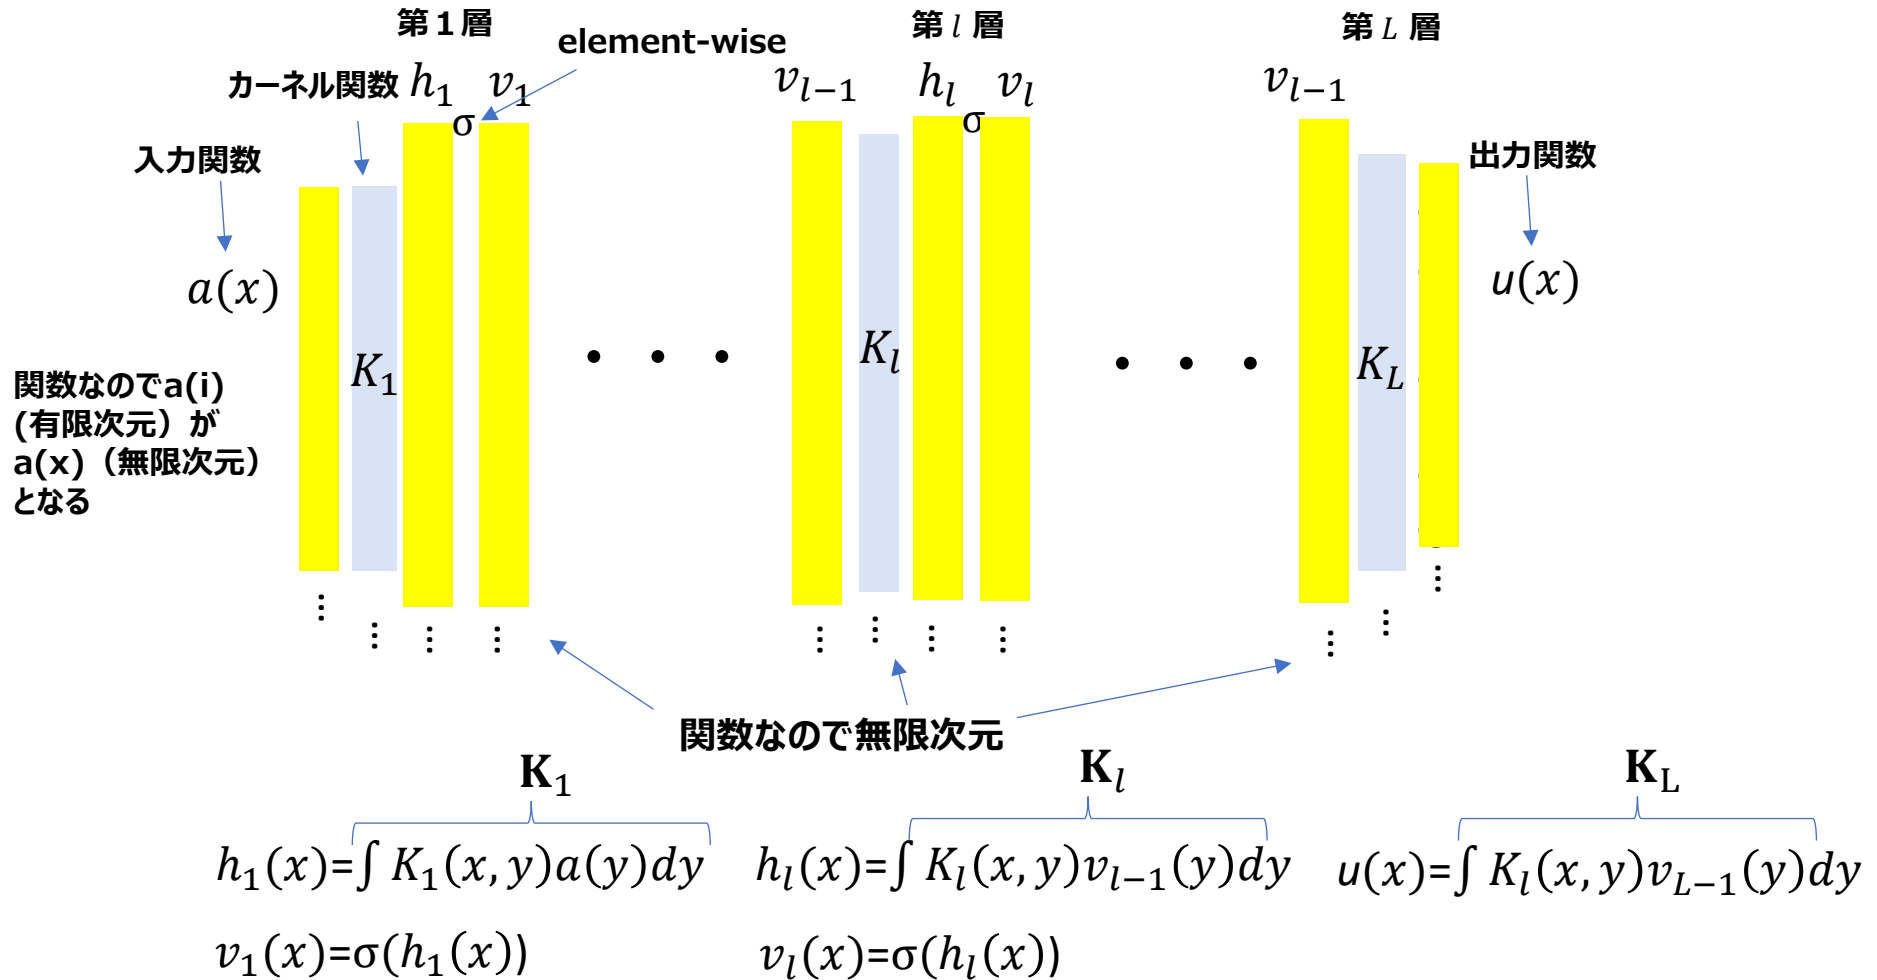
L層DNNのベクトル、行列表記

$$u = G(a) = K_L(\sigma(K_{L-1}(\sigma(\dots \sigma(K_1(a) \dots))))$$

Note: element-wiseの演算

無限次元拡張


関数間の写像を実現するには、NNの各層のノード(離散)を連続化したDNNを考えればよい




$$u = G(a) = K_L(\sigma(K_{L-1}(\sigma(\dots \sigma(K_1(a)) \dots)))$$

NOはDNNでのノードを連続拡張したものを見せる！

FNO: Fourier Neural Operator



U(x)の誤差を最小化するようにパラメータを学習する



$$(\mathcal{K}(a; \phi)v_t)(x) := \int_D \kappa(x, y, a(x), a(y); \phi)v_t(y)dy$$

カーネル積分作用素を周波数領域での畳み込み積分に置き換える

$$(\mathcal{K}(a; \phi)v_t)(x) = \mathcal{F}^{-1}(\mathcal{F}(\kappa_\phi) \cdot \mathcal{F}(v_t))(x)$$

畳み込み定理：元の空間における畳み込み積分は周波数領域では積になる

$$(\mathcal{K}(\phi)v_t)(x) = \mathcal{F}^{-1}\left(R_\phi \cdot (\mathcal{F}v_t)\right)(x)$$

↑
高周波をカット

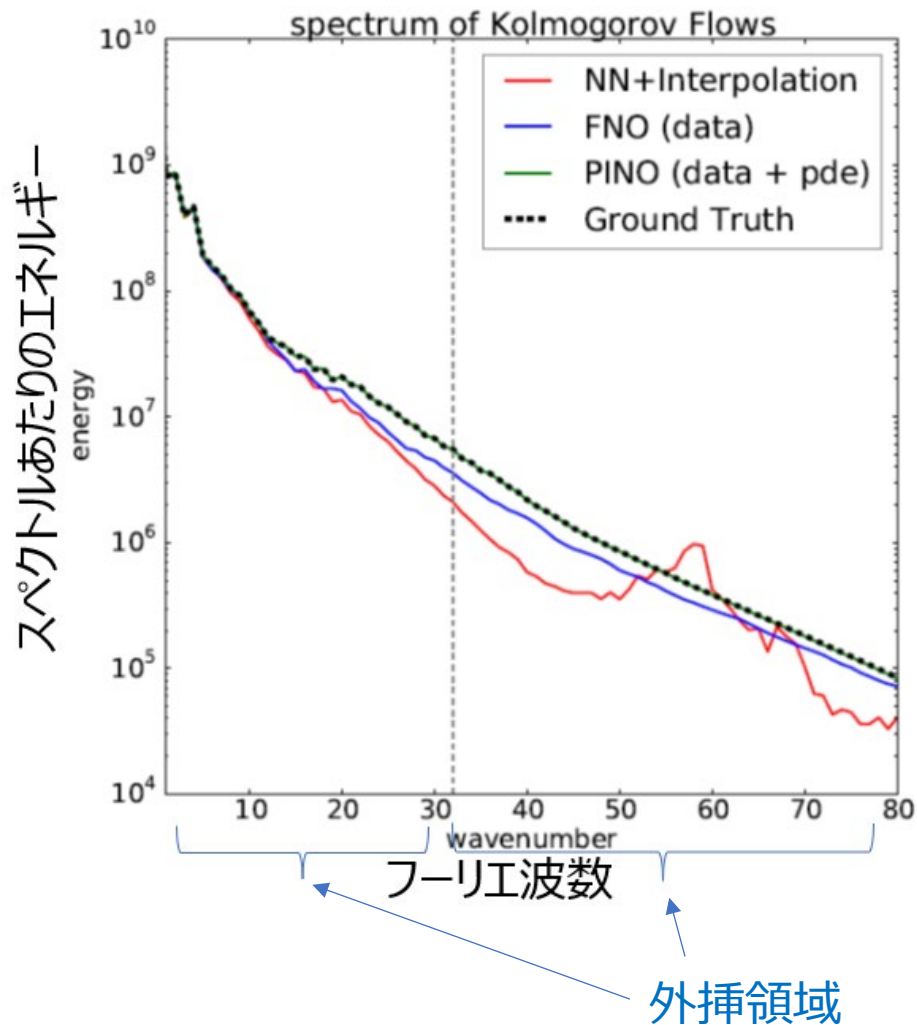
計算量：低周波成分だけだと $O(Nk_{\max})$, 高速フーリエ変換を用いると $O(N \log N)$

Neural Operator Learning for Hamiltonian and Dissipative PDEs

エネルギー保存則や散逸則といった物理法則を満たす偏微分方程式（PDE）の解演算子をデータから学習するための一般的な枠組みである「Energy-consistent Neural Operators（ENO）」を提案

Tanaka, Yaguchi, Iwata, Ueda, AISTATS2025

PINO: PINNと作用素学習の融合



PINO(FNO+PINN)は、学習データと損失に対するPDEを制約に入れているため完全に復元できている。

まとめ

データ駆動型アプローチ（機械学習）とモデル駆動型アプローチを相補的に融合 = シミュレーションベース機械学習の紹介

深層学習は、これまでend-to-end学習で様々な応用分野で用いられてきたが、BPの自動微分機能を生かして、ODE, PDEの学習、求解などへの発展途上にある（AI研究の進化！？）