

物理AIによる浸水深推定の高速化 手法への取り組み

寒地土木研究所 寒地河川チーム

○大石 哲也
堀田 伸之
前田 俊一

本研究では、物理法則を組み込んだ AI 技術である PINNs を用いて、限られた水理量の観測データから解析領域全体の浸水状況を推定するモデルを構築した。本モデルは、二次元浅水流方程式を損失関数に組み込むことで、数値解析で 40 時間要した計算を 5 分で得られることを示した。さらに、複雑な地形情報を効率的に反映できる K-Planes を導入し、標高データを事前学習させた。80 m および 320 m 間隔の観測地点数で性能を比較したところ、本モデルは観測地点が少ない状況でも高い再現性を示した。今後、物理 AI などの技術を活用することで、効率的な観測網設計や防災計画への活用、リアルタイムな洪水予測の展開が期待される。

キーワード：浸水把握、フィジカルAI、K-Planes

1. はじめに

近年、地球温暖化や気候変動に起因する甚大な水害が頻発しており、避難指示の対象となる住民が増加している。これを受け、水防法の改正・施行や「水防災意識社会再構築ビジョン」などが推進され、住民の自主的な避難行動を支援するための情報整備の重要性が一層高まっている。さらに 2021 年には、流域治水関連法が法制化され、流域全体で水害を軽減させる流域治水への転換により、土地利用と一体となった対策等が検討・実施されつつある。

このような状況下で、国土交通省は、流域内の浸水状況について安価な浸水センサーなどを活用した浸水実績の把握に取り組んでいる¹⁾。一方で、SAR 衛星解析、監視カメラ映像、市民からの投稿画像、IoT 水位計といった多様な観測手段が登場し、さらに物理法則を組み込んだ AI (物理 AI) 技術が発展してきたことにより、限定的な観測データから広域の浸水状況を高速かつ高精度に推定する手法の実現可能性が大きく向上している。

物理 AI の一分野である Physics-Informed Neural Networks (PINNs)²⁾ は、深層学習フレームワークが持つ自動微分機能を活用し、観測データと物理法則 (偏微分方程式) の両方を満たすように学習を進める技術である (図-1)。一般的な深層学習では、入力データと正解データを基に、両者の差から算出される損失を最小化する予測関数 (次元 (特徴量の数) と多層な構造でデザインされる) を学習する。一方、PINNs では、データ損失と物理損失の和を最小化する予測関数を学習する。このため、PINNs は、

少ない観測データからでも物理的に妥当な予測が可能である。また、ニューラルネットワークの特性により、数値解析手法で利用される計算格子への離散化が不要で高速な解析が可能である。実際に、洪水時の浸水解析において、最大 2 日程度要していた計算を数分に短縮した事例も報告されている³⁾。

しかし、PINNs にも課題は存在する。第一に、PINN 損失 (データ損失と物理損失の和) を十分に小さくできない場合、物理法則を正確に満たせない可能性がある。また、サンプリングする地点の密度を高めると精度は向上するが計算速度が低下するというトレードオフの関係がある。第二に、PINNs は現象を連続的な関数として近似するため、堤防のような不連続な地形の表現が本質的

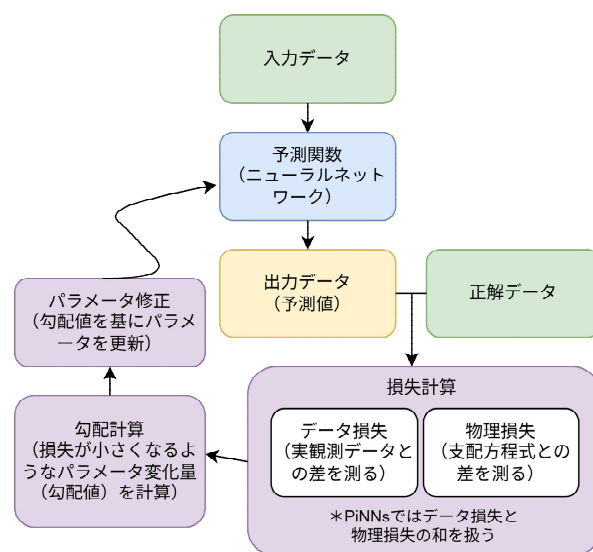


図-1 深層学習 (PINNs 含む) の学習の仕組み

に困難であるという点である。

これらの課題に対処するため、本研究では、3次元形状復元技術である NeRFs (Neural Radiance Fields) ⁴⁾ で用いられる位置エンコーディング手法「K-Planes⁵⁾」を利用し、PINNs に導入した。この改良により、従来の位置エンコーディングの手法（後述する）では困難だった低密度のサンプリング条件下でも、浸水状況の全体像を高い精度で推定が可能であるかを確かめた。さらに、K-Planes に対して事前に地形情報を学習させる独自の手法を構築することで、地形の複雑性や不連続性を考慮した浸水解析の実現可能性について検討した。

以上の背景と開発技術経緯を踏まえ、本報では、既知の浸水深や標高値から未知地点の浸水深を高速かつ高精度に推定する物理AIモデルを構築し、観測地点のサンプリング密度がモデルの推定精度に与える影響を評価することを目的とした。具体的には、サンプリング間隔の異なる条件下において、従来の位置エンコーディング手法（PE: Positional Encoding）と提案手法（K-Planes）の再現性を比較検証し、観測データが限定的な状況下における本手法の有効性を明らかにする。

2. 階層型グリッドベースの位置埋め込みの導入

PINNs は、非常に多様な視点での改良が検討されている⁶⁾。PINNs を洪水氾濫解析へ適用する上での主要な課題は、前述の通り、複雑な実地形における物理法則の厳密な再現と計算コストのバランス、そして堤防のような不連続地形の表現である。これらの課題解決を目指し、本研究では NeRFs 等で用いられる階層型グリッドベースの位置埋め込み手法である「K-Planes」に着目し、これをモデル内部（予測関数）の座標処理として組み込むこととした（図-2）。

K-Planes の導入は、時空間座標をより表現力の高い特徴量空間へ写像することを可能とする（図-3）。具体的には、複数の階層から得られた特徴量を連結することで、全体像と局所的なディテールの両方を同時に表現することを実現している。これにより、低密度なサンプリング点であっても物理法則に則った学習が可能となり、計算負荷を抑制しつつ高速な収束と高精度な予測が期待される。特に、地形情報を K-Planes に事前学習させる手法は、地形の複雑性や不連続性を効果的に捉え、物理的に整合した浸水特性を再現する上で重要な役割を果たす⁶⁾。

表-1 は、モデル構成および利点・欠点の観点から、PE（従来までの手法）と K-Planes（本研究で扱った手法）を比較したものである。PE は計算負荷が高くリアルタイム解析に課題を残すが、K-Planes はグリッド構造による特徴量の保持により、実装の複雑さとメモリ消費というコストを払うことで、「高速な収束」と「複雑地形への追従性」という性能を獲得している。

OISHI Tetsuya, HOTTA Nobuyuki, MAEDA Shun-ichi

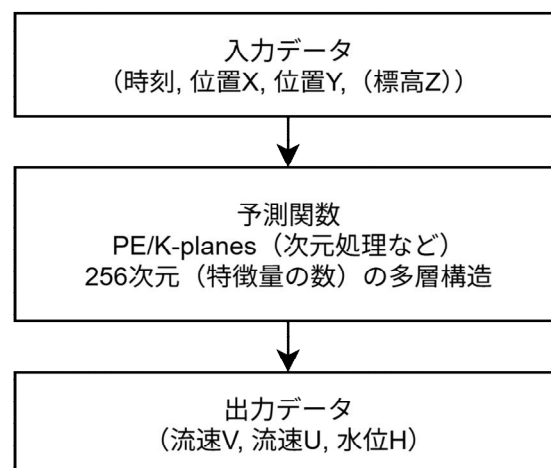


図-2 モデルの構成（概略図）

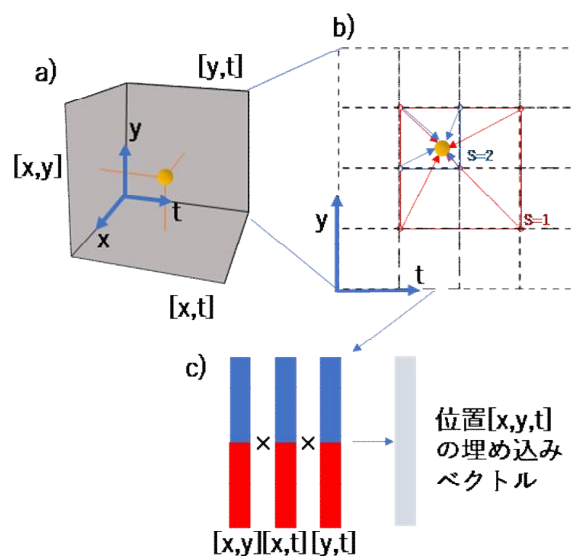


図-3 K-Planes の概略

a) 3次元上にある物体の位置（黄色の丸）を b) 2次元平面に投影し、粗い階層（S=1）と細かい階層（S=2）のそれぞれの4隅から値を拾って補間する。最終的に、c) 複数の階層から得られた特徴量を連結してベクトルとして格納する（全体像とディテールの両方が学習可能となる）。

3. モデルを利用した検証例

(1) サンプリング地点条件の検討

本手法による水位計算結果の妥当性を評価するため、実際の河川地形データ（図-4 参照、1.4 km × 3.8 km の範囲）及び過去の洪水イベントを模した数値解析結果を学習データとして用い、モデルの検証を行った。

実地形のデータセットは北海道のある流域の DEM デ

ータを元に作成し、二次元氾濫解析ソフトウェア iRIC Nays2DFlood（以降、iRIC）を用いて計算を実施し、外水氾濫の状況を仮想的に作り出した。なお、計算に要した時間は約 40 時間であった。この計算結果をランダムな地点（128 地点、200m 四方に 1 地点観測する程度のスケール感）で疑似観測し、未観測地点の水位の時系列変動が予測・再現できるかを確認することとした。

学習段階では、観測地点を128地点（200 m四方に1地点程度）に固定して行い、検証時にはPINN損失を評価するサンプリング地点の密度を変化させてPINNsの計算を実施することとした。具体的には、ケース(a)では80 m 四方に1点のサンプリング地点（計806点）、ケース(b)では320 m四方に1点のサンプリング地点（計80点）を与え、それぞれのデータで比較した。なお、正解データ（GT: Ground Truth）には、iRICによる数値解析結果（流況、水深等）を用いた。

(2) 水深結果の比較と考察

図-5 にサンプリング密度の違いによる水深分布の例を示す。1ステップは5分で、上から順に 100 分後、150 分後、200 分後の浸水範囲と水深分布が見てとれる。

高密度サンプリングでは、K-Planes、PE の両手法ともに、正解データ（GT）と比べて浸水の範囲や水深分布をよく捉える傾向にあった。特に K-Planes を用いた場合は、氾濫原の広がり比べて細長く水深が深くなる箇所（図中央の河道部分）でも PE に比べて再現性が高くなる可能性を示せた。

また、低密度なサンプリング条件下においても、K-Planes 導入モデルは河道沿いの水深分布や全体的な浸水範囲の傾向を良好に捉えることが確認された。一方、PE では、河道部分でやや不自然な水深分布（とくに低密度の Step30、Step40）となるなど、正解データとの差異が大きくなる傾向が認められた。なお、いずれのケースも計算出力は約5分であった。

以上から、K-Planes を導入した PINNs は、サンプリング地点が限られる条件下において、高い再現性を持ち、数値計算よりも高速に処理でき、浸水深の推定精度向上に寄与することが確認された。

4. まとめと今後の展望

本研究では、K-Planes を導入した PINNs により、観測地点が限定的な条件下においても高精度な浸水深推定の実現を図った。検証の結果、提案手法は従来手法（PE）に比して精緻な再現性を示し、データの希薄さに対して一定の頑健性を有することを確認した。

本研究で得られた主な成果および今後の展望を以下にまとめる。

- ・計算の高速化と物理的妥当性の確保：数値解析で約

表-1 PE と K-Planes との比較

比較項目	PE（従来までの手法）	K-Planes（本研究で扱った手法）
基本構造	<ul style="list-style-type: none"> ・時空間座標を直接利用（座標は計算式の変数として利用） ・全情報をネットワーク重みで表現 	<ul style="list-style-type: none"> ・座標を複数の2次元平面格子に投影（座標は場所探しとして利用） ・各平面から得た特徴量を結合
入力次元	4次元(t, x, y, z)	3次元(t, x, y) ※z（標高）は K-Planes の[x,y]平面に事前学習させ固定
利点	<ul style="list-style-type: none"> ・構造が非常に単純で、実装が容易 ・メモリ消費が少ない 	<ul style="list-style-type: none"> ・計算速度の高速化 ・複雑地形の再現性が高い（地形を事前学習するため）
欠点	<ul style="list-style-type: none"> ・高精度確保のためには、密なサンプリング点の必要性 ・計算量が膨大で、リアルタイム解析時には課題 	<ul style="list-style-type: none"> ・モデル構造が複雑であり、実装難易度が高い ・グリッドデータ（特徴ベクトル）の保持による大容量のメモリ消費


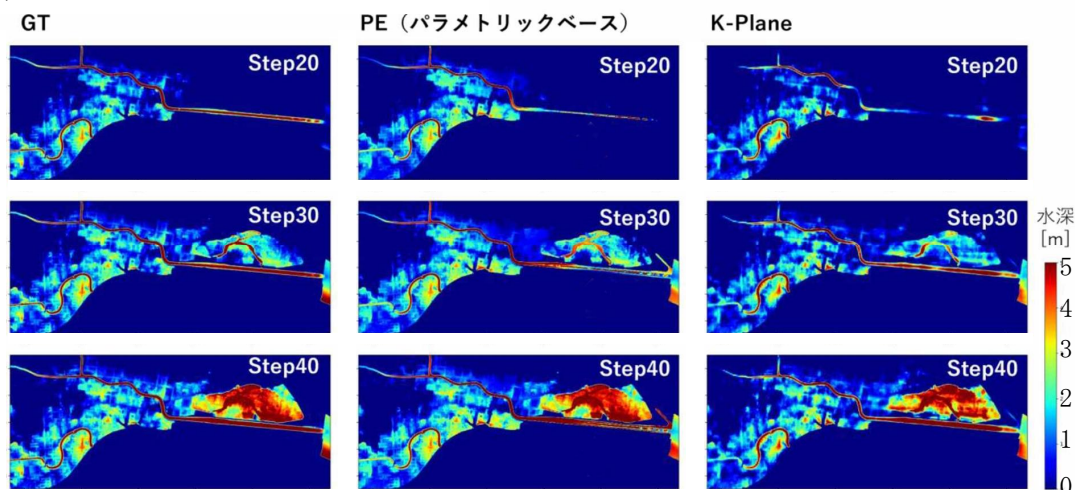


図-4 地形条件

40 時間を要した氾濫計算を 5 分程度に短縮し、損失関数に運動方程式を組み込むことで、物理的に妥当な浸水深推定が可能であることを確認した。

- ・低密度計測データの有効活用：80 m 四方(高密度)と 320 m 四方(低密度)の比較検証により、K-Planes モデルが観測地点の少ない条件下でも高い再現性を示し、効率的な観測網設計に寄与する知見を得た。
- ・地形情報の事前学習による複雑地形への対応：K-Planes に地形情報を事前学習させる手法により、堤防などの不連続な地形条件を考慮した浸水解析の実現可能性を示した。
- ・サロゲートモデルの開発と学習の高度化：現在、洪水浸水想定区域の推定に利用された氾濫解析データ 1 万ケース以上を学習データとし、数値計算の代替となるサロゲートモデルの開発を進めている。これにより不確実な地形条件に対して、より汎用的かつ堅牢な学習

a) 高密度 (80 m 四方に 1 地点)



b) 低密度 (320 m 四方に 1 地点)

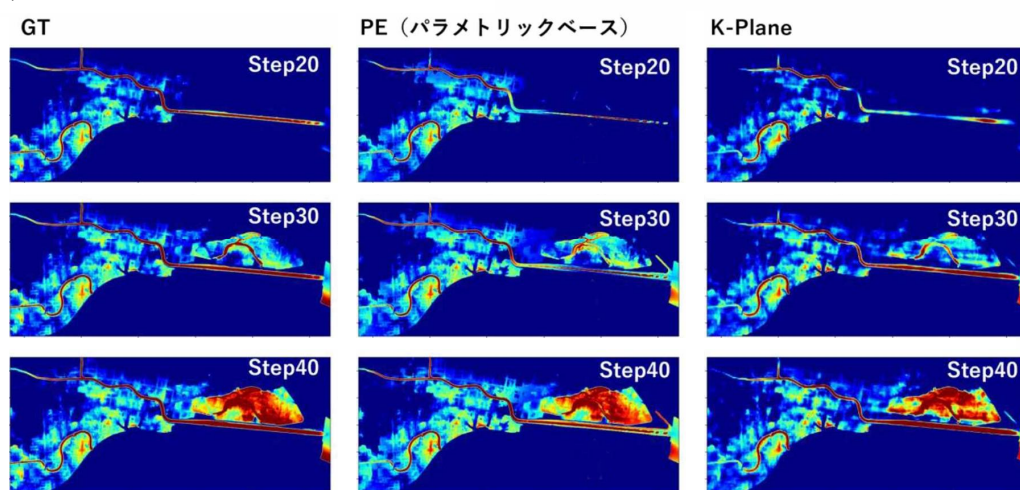


図-5 水深の計算結果の例 (部分図)

モデルの構築でき、確率的に氾濫予測が可能となることを目指している。今後、効率的な観測網設計や防災計画への活用、リアルタイムな氾濫情報への展開が期待できる。

参考文献

- 1) 国土交通省 | 報道資料 | 令和7年度は232の自治体で実証実験を行います。 https://www.mlit.go.jp/report/press/mizukokudo03_hh_001301.html (2026年1月8日確認)。
- 2) Raissi, M., Perdikaris, P., Karniadakis, G. E. : Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, *Journal of Computational Physics*, Vol. 378, pp. 686–707, 2019.
- 3) 阿部真己, 平松裕基, 大石哲也: 洪水時の外水氾濫を対象としたPhysics-Informed Neural Networksによる浸水把握の試み, *Ai・データサイエンス論文集*, Vol. 4, No. 3, pp. 638–645, 2023.
- 4) Mildenhall, Ben, Srinivasan, Pratul P., Tancik, Matthew, Barron, Jonathan T., Ramamoorthi, Ravi, Ng, Ren : NeRF: Representing Scenes as Neural Radiance Fields for View Synthesis, *arXiv:2003.08934*, arXiv, 2020.
- 5) Fridovich-Keil, Sara, Meanti, Giacomo, Warburg, Frederik, Recht, Benjamin, Kanazawa, Angjoo : K-Planes: Explicit Radiance Fields in Space, Time, and Appearance, *arXiv:2301.10241*, arXiv, 2023.
- 6) 阿部真己, 平松裕基, 大石哲也: 階層型グリッドベース位置埋め込みによる Physics-Informed Neural Networks を用いた洪水氾濫解析の高度化の試み, *Ai・データサイエンス論文集*, Vol. 5, No. 3, pp. 337–348, 2024.