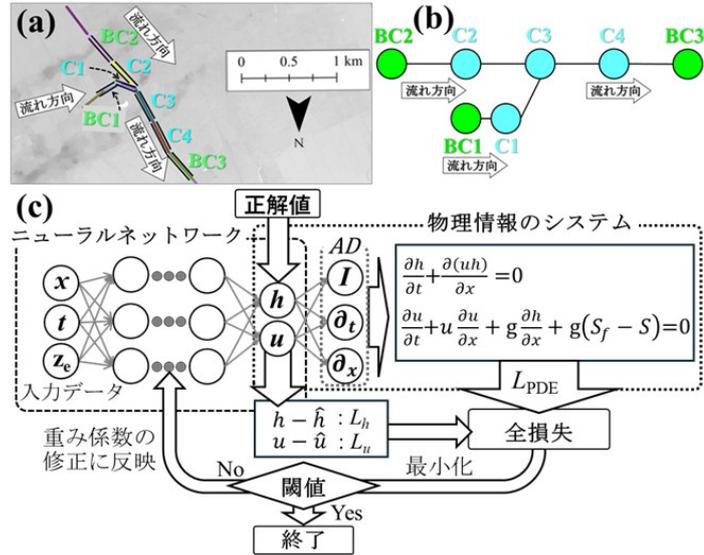


2つの排水路の合流情報を考慮したPINNによる洪水の再現計算の検証 Verification of PINN-based flood simulations considering the confluence of two drainage canals

○木村延明*・皆川裕樹**・木村匡臣***
○Nobuaki KIMURA・Hiroki MINAKAWA・Masaomi KIMURA

1. はじめに

近年、河川洪水等を迅速に予測するために、観測地点で収集されるデータと長・短期記憶(LSTM)等の深層学習を用いた水位予測モデルが開発されてきた。しかし、深層学習はデータが得られない地点での学習が困難であるために、近年、物理情報を導入した深層学習(PINN)の活用が注目されている。木村ら¹⁾は、予め生成された洪水疑似データ(1h間隔の5日間)を観測値の代用として用いて、PINNに1次元浅水方程式(SVE)を導入し、対象地域の排水用の直線水路に適用した。しかし、PINNの実用化のためには、複数の支線水路の合流等の情報を考慮する必要がある。本報では、PINNにグラフ的な合流情報を埋め込んだモデル(GPINN)を構築し、その再現計算の精度検証を行う。



凡例: x, t, z_e =位置(m), 時間(h), グラフ埋め込み情報; h, u =水深(m), 流速(m/s); \hat{h}, \hat{u} =近似値; g =重力加速度(m/s^2); S =摩擦勾配; PDE=偏微分方程式; L_i =損失関数($i = h, u, \text{ \& PDE}$); AD=自動微分(恒等演算子(I)と微分演算子(∂_x, ∂_t)等の演算子を使用して、コンピュータプログラムによって定義される偏微分関数を評価するアルゴリズム)

図1 モデルの諸情報: (a)水路情報, (b)グラフ埋め込みの位置情報, (c)GPINNの構造とデータフロー図
GPINN features: (a) drainage canals, (b) Graph embedding information, and (c) GPINN structure & dataflow

2. 方法

先行研究¹⁾で開発したPINNはSVEの導入により、位置(x)・時間(t)に対応した水路の流速(u)・水深(h)を学習し、学習済みPINNを用いればシミュレーション(再現計算)が可能である。GPINNは、このPINNに水路の合流情報を埋め込んだモデルである。計算方法では、300mm/hの豪雨から生成された洪水疑似データを正解値と見なして、2つの支線水路を再現するために、上流に2つ、下流に1つを境界とする水路セル(BC_i, i =番号)を定義し、また、 BC_i に挟まれた水路セル(C_i)を計算点(正解値を与えない点)とした(図1a)。水路セル C_3 の合流情報の埋め込み方法は、図1bのように位置情報をPINNに与えること(グラフ埋め込み機能²⁾)で対応した。なお、グラフ埋め込み機能を用いた位置情報では、 $C_1 \rightarrow C_3$ の支線と $C_2 \rightarrow C_3$ の支線が交差しないように設定した。本モデルの構造は、図1cに示す通り深層学習部とSVE部をリンクさせ、グラフ埋め込み機能として位置情報(z_e)を入力データとして加えている。時空間を含むPINN/GPINNの計算領域は、図2に示す通りである。なお、PINN/GPINN

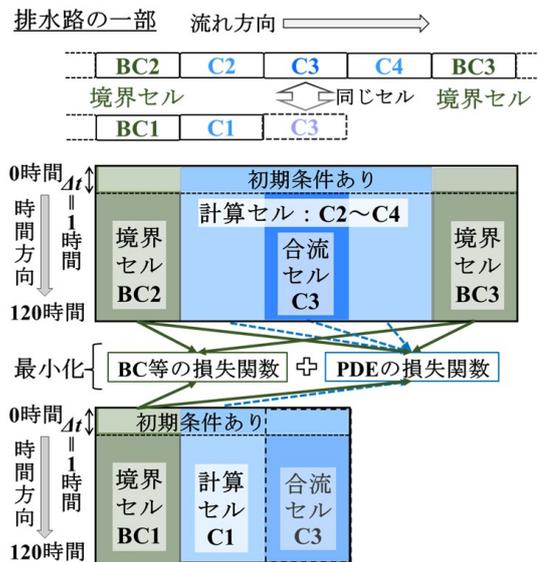


図2 PINN/GPINNの計算情報
Calculation information for PINN/GPINN

*西九州大学 Nishi-Kyushu Univ. **農研機構農工部門 NARO Inst. Rural Eng., ***近畿大学 Kindai Univ.
キーワード PINN/GPINN, 2つの水路の合流条件, グラフ埋め込み機能, 洪水再現計算

の損失関数, ハイパーパラメータ等の計算条件は, Feng et al.²⁾を参考にした(例: Epoch数=60,000, NN 中間層の数=3, Node 数=64)。精度検証の方法は, 正解値と再現計算値の誤差等を評価するために, 二乗平均平方根誤差(RMSE), 最大水深時のピーク値の差(DfPk)等を用いた。

3. 再現計算の結果

雨量パターンが異なる複数の疑似洪水データの計算後に, 比較的良好な結果(2つの強い降雨あり)が得られたケースについて検討する。図3に GPINN(合流情報あり)と PINN(合流情報なし)の再現計算(u, h)の結果と正解値の比較を示す。流速では, 合流点 C3 で計算時間 40 h まで GPINN は良好な結果であったものの, それ以降は過小評価が見られた。他の計算点でも同様に再現が困難で, むしろ PINN よりも計算精度が悪化した(図3a)。一方, C3 の GPINN の水深計算では, ピーク値を正確に再現できないものの, PINN よりも RMSE で約 10%, DfPk で約 40%の改善が見られた。また, NSE は 0.7 以上であった。他地点でも PINN の再現計算を大幅に改善したことを示した(図3b)。しかし, GPINN の計算結果は滑らかに変化する波形を出力するので, 流速のように急激な変化を伴う現実的な波形に対しては, 再現が困難であることを示した。

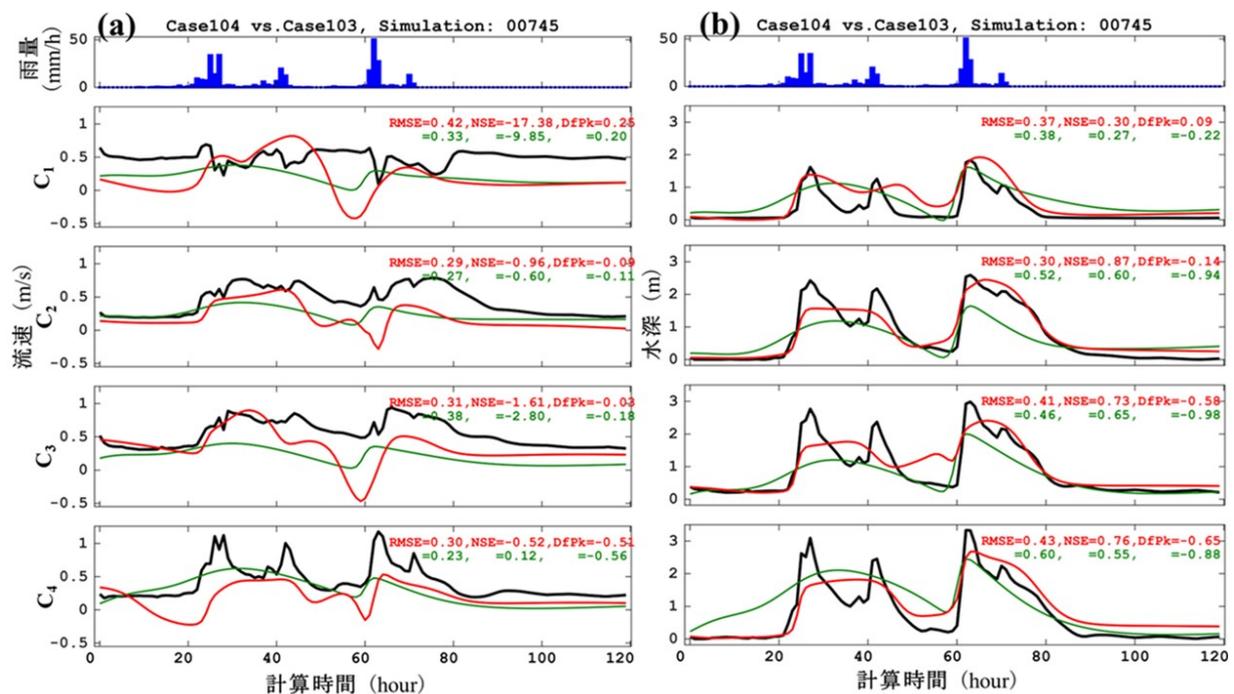


図3 雨量(青色)と GPINN(赤線)と既往研究の PINN(緑線)の水路セル(上流→下流: C1→C4)における(a)流速(u)と(b)水深(h)の再現計算の結果と正解値(黒線)の比較図

Temporal variations of rainfall, and velocity (u) and depth (h) of true value (black), compared with GPINN (red) and conventional PINN (blue) predictions in upstream to downstream canals, whose IDs are C1 to C4.

謝辞: 本報の研究は, 内閣府総合科学技術・イノベーション会議 SIP3 期(スマート防災ネットワークの構築: JPJ012289, 推進機関: (国研)防災科研)の助成を受けて実施された。(株)アーク情報システムの馬場大地氏の研究協力を受けた。本研究への支援に謝意を表明する。

【参考文献】1)木村ら: 1次元非定常流計算を導入した Physics-informed neural networks(PINN)の開水路流れへの適用. 土木学会論文集特集号(水工学), 81巻16号24-16189, 2025; 2)Feng et al.: Physics-informed neural networks of the Saint-Venant equations for downscaling a large-scale river model. *Water Resources Research*, Vol. 59, e2022WR033168, 2023; 3)皆川ら: 排水施設の操作支援のための深層学習水位予測モデル構築にむけた模擬データ活用法の検討. 土木学会論文集 B1(水工学), 76巻2号, pp.I_349-I_354, 2020.