

目 次

研究課題名	学年	氏名	頁
NURBS-Enhanced FEM(NEFEM) を用いた 流体構造連成解析手法の構築	博士前期課程 2 年	三宅 智大	1
次元圧縮手法を適用した深層学習による リアルタイム浸水域予測手法の構築	博士前期課程 2 年	中山 龍也	5
次元圧縮と深層学習を用いた 浸水域予測手法における適用性評価	博士前期課程 1 年	山口 歓太	9
点群データを用いた粗度係数算出手法における ドメインギャップの定量化と他地域への適用性検証	博士前期課程 1 年	大舘 雄介	13
XREAL を用いたデジタルマーカース手法に基づく MR 可視化システムの構築	博士前期課程 1 年	石川 隼也	17
スマートグラス XREAL を用いた 土木構造物の MR 可視化システムの構築	学部 4 年	船江 倅郁	21
有限要素法に基づく遮音壁の 吸音効果を考慮した音場解析	学部 4 年	三矢 諒音	23
VR 技術を用いた HMD 型浮上式高速鉄道騒音評価システムの構築	学部 4 年	増田 樹	25
VR 技術を用いた 超音速機騒音評価システムの実用性の向上	学部 4 年	太田 絢乃	27
ベイズ最適化を用いた リアルタイム浸水域予測モデルの高精度化の検討	学部 4 年	長濱 悠太郎	29
深層学習を用いた山向き小崖の自動抽出における 損失関数の最適化	学部 4 年	藤ノ木 東周	33
深層学習を用いた土地利用分類における 入力画像の空間的範囲が精度に与える影響の検討	学部 4 年	堀越 誠一郎	37
不連続 Galerkin 法に基づく p -Adaptive 解析手法の構築	学部 4 年	木村 伊吹	39

NURBS-Enhanced FEM(NEFEM) を用いた流体構造連成解析手法の構築

Development of a Fluid-Structure Interaction Analysis Method
using NURBS-Enhanced FEM (NEFEM)

都市人間環境学専攻博士前期課程 2 年 三宅 智大
Tomohiro MIYAKE

1. はじめに

土木分野において、風力発電施設や球形タンクなど流体と構造が相互に影響し合う現象を把握することは安全な設計のために重要である。現象を解明するための解析を精度よく行うためには、構造表面の幾何形状を正確に再現することが重要となる。任意形状の解析に優れている手法として有限要素法 (FEM) があるが、より幾何形状を厳密に表現できる手法として Isogeometric Analysis (IGA)¹⁾ がある。IGA は、CAD で広く用いられる NURBS を基底関数とすることで形状再現性に優れているが、領域全体に高次関数を適用するため、FEM に比べて計算コストが大きい。そこで本研究では、境界の形状表現のみに NURBS 関数を用いて計算時間を抑える NURBS-Enhanced Finite Element Method (NEFEM)²⁾ に着目した。

本研究では、NEFEM を用いた流体構造連成解析手法の構築を目的とする。その第一段階として、NEFEM の流体解析手法の妥当性検証のため、2次元円柱周り流れ解析を、NEFEM 流体構造連成解析手法の妥当性の検証のため2次元渦励振解析を行った。低レイノルズ数域に着目し、解析精度と計算コストについて実験値および従来の FEM と比較・検討を行った。

2. 数値解析手法

2.1 流体構造連成解析手法のアルゴリズム

流体構造連成解析のフローチャートを図-1 に示す。本研究では、流体の計算と構造の計算を別々に解く弱連成解析を採用している。

2.2 流体解析における支配方程式

2次元非圧縮性粘性流体の支配方程式は、以下に示す ALE 記述された Navier-Stokes の運動方程式と連続式である。

$$\rho \frac{\partial u_i}{\partial t} + \rho \bar{u}_j \frac{\partial u_i}{\partial x_j} + \frac{\partial p}{\partial x_i} - \mu \frac{\partial}{\partial x_j} \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) = \rho f_i \quad (1)$$

$$\frac{\partial u_i}{\partial x_i} = 0 \quad (2)$$

ここに、 u_i は i 方向の速度成分、 $\bar{u}_i$ は i 方向の相対速度、 p は圧力、 ρ は密度、 μ は粘性係数、 f_i は物体力で




図-1 流体構造連成解析手法のフローチャート

ある。境界条件は以下ようになる。

$$u_i = \hat{u}_i \quad \text{on } \Gamma_g \quad (3)$$

$$\left(-p\delta_{ij} + \mu \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) \right) n_j = \hat{t}_i \quad \text{on } \Gamma_h \quad (4)$$

ここで、 $\hat{u}_i$ は既知量、 n_j は境界外向き単位法線ベクトル、 δ_{ij} は Kronecker のデルタ、 Γ_g 、 Γ_h はそれぞれ Dirichlet 境界条件と Neumann 境界条件が与えられる境界である。

2.3 離散化手法

支配方程式 (1)(2) に対し、SUPG/PSPG 法³⁾ に基づく安定化有限要素法を適用する。三角形 1 次要素を用いて空間方向の離散化を行い、Crank-Nicolson 法を用いて時間方向の離散化を行う。また、移流速度は 2 次精度 Adams-Bashforth 法を用いることで線形化し、簡易的に方程式を解く。なお、一連の離散化手法は FEM、NEFEM いずれも同じである。




図-2 重みを変化させた NURBS 曲線

2.4 構造解析における支配方程式と離散化手法

構造解析における支配方程式は式 (5) に示す 1 自由度系の運動方程式である。

$$m\ddot{d}(t) + c\dot{d}(t) + kd(t) = F(t) \quad (5)$$

ここで、 m は構造物の質量、 c は減衰係数、 k は剛性係数、 $d(t)$ は変位、 $F(t)$ は外力である。なお、構造物は剛体とし、流れに対して垂直に 1 方向のみ動くばね・マスダンパー系を仮定する。時間方向の離散化には、Newmark- β 法を用いる。

2.5 流体領域内の節点再配置手法

構造物の運動と変位に合わせて、各時間ステップにおいて流体領域内のメッシュを更新する必要がある。解析により得られた変位を境界値とした、領域内節点変位分布に関する Laplace 方程式を解くことにより節点の移動量を求める。基礎方程式は以下ようになる。

$$\nabla^2 \phi = 0 \quad \text{in } \Omega \quad (6)$$

ここで、 ϕ は節点変位量である。また、境界条件は以下のようになる。

$$\phi = d \quad \text{on } \Gamma_m \quad (7)$$

$$\phi = 0 \quad \text{on } \Gamma_f \quad (8)$$

ここで、 Γ_m, Γ_f はそれぞれ移動境界、固定境界を表す。有限要素法により離散化を行い、節点変位量を求解する。これによりメッシュ更新を行う。

2.6 NURBS

NEFEM では解析領域の形状表現に CAD で広く用いられる NURBS (Non-Uniform Rational B-Splines) を用いる。NURBS は少ない自由度で滑らかな形状を表現することができる関数である。NURBS 関数は以下の式で表される。

$$R_{i,p}(\xi) = \frac{N_i^p(\xi)w_i}{\sum_{i=1}^n N_i^p(\xi)w_i} \quad (9)$$

ここに、 N_i^p は B-Spline 基底関数、 w_i は制御点ごとに与えられる重みである。式 (9) と制御点の座標値の線形結合により NURBS 曲線を描くことが可能になる。図-2 に示すように制御点における重みを変化させることで曲線の形状を変えることができ、正確な円を表現できる。

NEFEM では、解析領域のうち曲線に接する境界要素の形状補間に NURBS を用いることで、CAD で定義




図-3 TRT マッピング

された境界形状を正確に表現することが可能になる。なお、物理量の補間には FEM と同じ基底関数（本研究では 1 次関数）を用いる。また、曲線を持たない内部要素の基底関数には FEM と同じように 1 次関数を用いることで、領域全体の基底関数に高次関数である NURBS を用いる IGA に比べて計算コストを抑えることができる。

2.7 NEFEM の形状補間

NEFEM の境界要素における形状補間を行うため、座標変換を行う必要がある。その手法として、本研究では TRT (Triangle-Rectangle-Triangle) マッピング⁴⁾を用いる。通常の FEM では、パラメトリック空間の三角形参照要素で積分計算を行い、実要素へ座標変換を行う。NEFEM における TRT マッピングでは、図-3 に示すように四角形参照要素を間に用いることで、NURBS 曲線に合わせて座標変換を行うことが可能になる。TRT マッピングは以下の式で表せる。

$$\Phi_{TRT} = \sum_{i=1}^n N_i \mathbf{x}_i + \left(\sum_{j=1}^s N_j \right) \mathbf{C}(\chi) \quad (10)$$

$$\chi = \frac{\sum_{j=1}^s N_j \chi_j}{\sum_{j=1}^s N_j} \quad (11)$$

ここで、 n は内部節点（曲線上にない点）の数、 s は曲線上の節点の数であり、今回用いる三角形要素では $n = 1, s = 2$ である。 N_i は FEM の基底関数（本研究では 1 次関数）、 $\mathbf{x}_i$ は内部節点の実座標値、 $\mathbf{C}$ は NURBS 曲線、 χ は NURBS 曲線上のパラメトリック座標値、 χ_j は曲線上の節点の局所座標値である。




図-4 解析モデル・境界条件（円柱周り流れ解析）




図-6 抗力係数の実験値との比較




図-5 解析メッシュ（円柱近傍）

3. 数値解析例

3.1 2次元円柱周り流れ解析

NEFEMによる流体解析手法の妥当性と優位性の検証を行うため、2次元円柱周り流れ解析を行った。

3.1.1 解析条件

図-4に解析モデルと境界条件を示す。左側にレイノルズ数に応じた一様流速を与え、円柱表面に nonslip 条件、壁面に slip 条件を与える。密度は $\rho = 1.0[\text{g}/\text{cm}^3]$ 、粘性係数は $\mu = 0.01[\text{g}/(\text{cm} \cdot \text{s})]$ 、微小時間増分量は $\Delta t = 0.001[\text{s}]$ 、総計算ステップは 15000step とした。図-5に解析メッシュを示す。円柱周りを 16, 24 分割した 2 種類のメッシュを用いる。FEM のメッシュでは、節点間を直線で結んだ三角形要素となるため、円を多角形近似する。一方で NEFEM の境界要素では NURBS を用いることにより円を正確に表現したメッシュとなる。

3.1.2 解析結果

図-6に流れが安定した後の抗力係数の平均値の実験値⁵⁾との比較を、図-7にストローハル数を実験値⁶⁾との比較を示す。抗力係数・ストローハル数ともに、両メッシュにおいても、NEFEM は FEM とほぼ同等の値であり、実験値ともよい一致を示す。図-8に計算時間の比較を示す。NEFEM は FEM とほぼ同等の計算時間で解析可能であることを確認した。




図-7 ストローハル数の実験値との比較

3.2 渦励振解析

NEFEMによる流体構造連成解析手法の妥当性と優位性の検証を行うため、2次元渦励振解析を行った。

3.2.1 解析条件

図-9に解析モデルと境界条件を示す。解析形状、境界条件は円柱周り流れ解析と同じであり、円柱が 1 方向に振動するモデルである。また、解析メッシュ、解析条件も円柱周り流れ解析で使用したのと同じである。円柱の振動に関わるパラメータとして、円柱の質量は $m = 2.979[\text{g}]$ 、減衰係数は $c = 0.325[\text{g}/(\text{cm} \cdot \text{s})]$ 、剛性係数は $k = 5790[\text{g}/\text{s}^2]$ 、固有振動数は $f_s = 7.016[\text{Hz}]$ である。

3.2.2 解析結果

図-10に振動周波数と固有振動数の比の実験値⁶⁾との比較を示す。Re=113~117の範囲で FEM, NEFEM とともに 1 となり、固有振動数と渦発生周波数が一致していることが確認できる。図-11に円柱振幅の実験値⁶⁾との比較を示す。周波数比が 1 となる Re=113 から 117 の範囲で両手法ともに振幅が大きくなっており、共振していることが確認できる。また、NEFEM と FEM を比較




図-8 計算時間の比較




図-10 振動周波数と固有振動数の比の実験値との比較




図-9 解析モデル・境界条件（渦励振解析）




図-11 円柱振幅の実験値との比較

すると、NEFEMの方が振幅が大きく、より実験値に近い値をとることが確認できる。しかし、実験値と比較すると振幅が小さくなっており、ロックイン現象が発生するReの範囲も狭いことが確認できる。これは、格子解像度や流体・構造の連成パラメータの適合不足が要因と考えられる。

4. おわりに

本研究では、NEFEMを用いた流体構造連成解析手法を構築し、以下の結論を得た。

- 静止円柱まわりの流体解析において、NEFEMは従来のFEMと同等の計算精度および計算時間で解析が可能であることを確認し、手法の妥当性を示した。
- 2次元渦励振解析において、NEFEMによる流体構造連成解析手法の妥当性を確認したが、実験値と比較して振幅が小さくなっており、ロックイン現象が発生するReの範囲も狭いことが確認された。

今後の課題として、NEFEMの優位性を検討、構造物

を弾性体として変形を考慮したNEFEM流体構造連成解析の実施、および曲線形状を持つ遮音壁周りの波動音響解析へのNEFEMの適用などが挙げられる。

参考文献

- 1) T.J.R.Hughes, J.A.Cottrell and Y.Bazilevs, Isogeometric analysis: CAD, finite elements, NURBS, exact geometry and mesh refinement, Computer Methods in Applied Mechanics and Engineering, Vol.194, pp.4135-4195, 2005.
- 2) R.Sevilla, S.Fernandez and A.Huerta, NURBS - enhanced finite element method (NEFEM), International Journal for Numerical Methods in Engineering, vol76, pp56-83, 2008.
- 3) T. E. Tezduyar, Stabilized finite element formulations for incompressible flow computations, Adv. Appl. Mech., vol28, pp1-44, 1991.
- 4) N.Hosters, J.Helmig, A.Stavrev, M.Behr, S.Elgeti, Fluid-Structure Interaction with NURBS-Based Coupling, RWTH Aachen University, 2018.
- 5) Ronald L. Panton, Incompressible Flow. 4th ed., Wiley, 2013.
- 6) M. M. Zdravkovich, Flow Around Circular Cylinders, Oxford Science Publications, vol1, 1997

次元圧縮手法を適用した深層学習によるリアルタイム浸水域予測手法の構築 Development of a Real-Time Flood Inundation Prediction Framework Using Deep Learning Enhanced by Dimensionality Reduction

都市人間環境学専攻 修士 2 年 中山 龍也
Ryuya NAKAYAMA

1. はじめに

近年、地球温暖化に伴う気候変動の影響により、短時間強雨や線状降水帯の発生頻度が増加しており、それに起因する河川氾濫が各地で頻発している。2019 年の台風 19 号や 2020 年の 7 月豪雨をはじめとする大規模水害は広域にわたる甚大な被害をもたらしており、浸水情報の迅速な把握と共有の重要性は年々高まっている。氾濫発生から浸水拡大までの時間は限られており、住民の避難行動や行政の応急対応を支援するためには、リアルタイムあるいは事前シナリオに基づく浸水域の即時予測が強く求められている。従来、氾濫解析には平面二次元不定流モデルをはじめとする物理ベースの数値シミュレーションが広く用いられており、浸水域・浸水深の時空間的变化を高精度に再現することが可能である。しかし、解析対象領域の広さやメッシュ解像度によっては単一シナリオの計算に数時間から数十時間を要する場合があります。リアルタイム予測への直接適用は現実的ではない。このような背景から、物理モデルの精度を活かしつつ計算負荷を大幅に削減する代替アプローチの開発が喫緊の課題となっている。そのための有力な手段として、物理シミュレーション結果をオフライン学習データとして活用し、学習済みモデルによる数秒オーダーの即時計算を実現する機械学習を用いたリアルタイム浸水域予測の研究が近年活発に進められている。高次元な空間データを直接扱う際の計算負荷や過学習リスクを低減するため、浸水域データに次元圧縮を施して低次元表現に変換し、その空間内で時系列予測を行う二段階アーキテクチャが多くの研究で採用されている。既往研究¹⁾では、浸水域データに次元圧縮を適用して低次元の潜在表現を抽出したうえで、越流水深を入力として深層学習モデルにより低次元空間内の時間発展を予測し、復元器により元の解像度の浸水域に再構成する手法が提案されている。この枠組みは計算量削減の面で有望であるが、時系列モデルの構造が精度と計算時間のトレードオフに及ぼす影響については体系的な比較検討が十分とは言えず、改善の余地が残されている。そこで本研究では、複数地点越流に対応した浸水域の時系列予測を対象として、次元圧縮手法と時系列深層学習手法の組み合わせによる予測性能の体系的な比較・評価を行う。次元圧縮手法には、特異値分解（以後 SVD）²⁾、非負値行列因子展開（以後 NMF）³⁾、オートエンコーダ（以後 AE）⁴⁾ の 3 手法を、時系列学習モデルには Long Short-Term Memory（以後 LSTM）と Temporal Convolution Network（以後 TCN）の 2 手法を採用する。計 6 種類の組み合わせについて、浸水深の

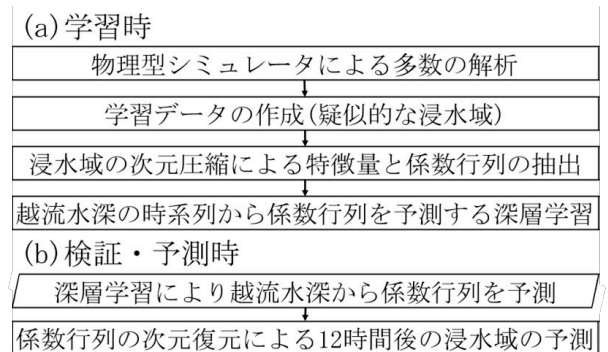


図-1 浸水域予測モデルの構築・浸水域の推定




図-2 対象領域とその標高

RMSE や浸水域一致率等による予測精度と推論計算時間の両面から比較・検討を行い、実用的なリアルタイム浸水域予測システムの構築に向けて最も有効な手法の組み合わせを明らかにすることを目的とする。

2. 学習データについて

モデル構築のフローチャートは図-1、本研究で使用する学習データの対象地域を図-2 に示す。

2.1 モデル構築と解析の手順

本研究では、越流水深を入力として浸水域を推定するリアルタイム予測手法の構築フローを図-1に示す。学習段階では、氾濫解析で得られた浸水域データに次元圧縮を適用し、係数行列を抽出する。推論段階では、時系列の越流水深から係数行列を予測し、特徴量との積により浸水域を再構成する。開発環境は CPU：Intel Core i7-12700F, RAM：32GB, GPU：NVIDIA RTX 3070 (8GB), Python 3.9 および TensorFlow を用いた。

2.2 浸水解析モデル

氾濫浸水解析には、一言ら⁴⁾が使用した氾濫水の挙動を精密に表現可能な Dynamic Wave 法を適用した浸水解析モデルを用いた。x, y 方向の運動量保存式と質量保存式は以下のとおりである。

$$\frac{\partial M}{\partial t} + \frac{\partial(uM)}{\partial x} + \frac{\partial(vN)}{\partial y} + gh \frac{\partial H}{\partial x} = -gh \frac{n^2 u \sqrt{u^2 + v^2}}{R^{\frac{4}{3}}} \quad (1)$$

$$\frac{\partial N}{\partial t} + \frac{\partial(uN)}{\partial x} + \frac{\partial(vN)}{\partial y} + gh \frac{\partial H}{\partial y} = -gh \frac{n^2 v \sqrt{u^2 + v^2}}{R^{\frac{4}{3}}} \quad (2)$$

$$\frac{\partial h}{\partial t} + \frac{\partial M}{\partial x} + \frac{\partial N}{\partial y} = 0 \quad (3)$$

ここで、 u は x 方向の流速、 v は y 方向の流速、 h は水深、 H は基準面からの水位、 R は径深、 $M = uh$ は x 方向の単位幅流量、 $N = vh$ は y 方向の単位幅流量、 g は重力加速度、 n はマンニングの粗度係数である。なお、空間方向の離散化手法は有限差分法、時間方向の離散化では陽解法を使用し、タイムステップは 0.2(s)。粗度係数は、基盤地図情報の土地利用分類⁶⁾に応じて設定している。

2.3 学習データ

本研究では、2 地点越流における 1 時間ごとの越流水深を入力とし、洪水氾濫解析で得られた浸水深を学習データとした。対象地域は荒川下流デルタ地帯とし、越流地点および標高分布を図-2に示す。標高・土地利用データは国土地理院の国土数値情報を用い、25m 格子に最近隣内挿法を適用して取得した。越流水深の時系列は、正弦波にノイズを与えた式 (2) により設定した。

$$h = \left\{ \sin \left(a - 0.5 + \pi \times \frac{t}{720} \right) + 0.3b \right\} \times 2c \quad (4)$$

ここで、 a, b, c は 0~1 の乱数、 t は時間 (分) を表す。図-3 は、平均越流水深が最大となる場合の時系列変化の一例を示す。地点 A, B からの越流および同時越流の 3 条件とし、各 1,000 ケース、計 3,000 ケースの氾濫解析を行った。図-4 は、各越流条件における平均越流水深最大ケースの浸水解析結果を示す。

3. 次元圧縮手法及び予測手法

3.1 次元圧縮手法

次元圧縮とは、高次元データの本質的特徴を保持したまま低次元で表現する手法である。本研究では、浸水解析




図-3 越流水深データについて




図-4 氾濫シミュレーションによる解析結果

領域の格子点数を圧縮前の次元数とし、線形手法である SVD, 非負制約を持つ NMF, および非線形表現が可能な AE を、浸水解析手法で得られた 12 時間後の浸水域データに適用した。

3.2 TCN (Temporal Convolution Network)

本研究では、リアルタイム浸水域予測における新たな時系列モデルとして TCN を導入した。TCN は畳み込みニューラルネットワークを時系列データに適用したモデルであり、再帰構造を用いずに時間依存性を捉えることができる。因果畳み込みおよび拡張畳み込みにより、未来情報を参照せずに長期依存関係を学習可能である。TCN は畳み込みに基づく並列計算が可能であり、高速かつ安定な学習・推論が可能である。これらの特性は、計算時間の短縮が求められるリアルタイム浸水域予測に有利であることから、本研究では TCN を主要手法として採用した。

3.3 LSTM (Long-Short Term Memory)

本研究では、TCN の性能を評価するための比較手法として LSTM を用いた。LSTM は再帰型ニューラルネットワーク (RNN) の一種であり、ゲート機構により勾配消失問題を抑制しつつ長期的な依存関係を学習できる点に特徴がある。越流水深は時間的に連続したデータであり、将来の浸水域形成に影響を与えることから、LSTM は代表的な時系列モデルである。本研究では、この LSTM を基準モデルとして TCN との予測精度および計算効率の比較を行った。

4. 標準化

本研究では、学習効率と数値計算の安定性向上のため、説明変数および目的変数を平均 0、分散 1 となるよう標準

表-1 次元圧縮の実行条件

対象データ	12 時間後の 3000case の氾濫域
入力次元数	221392 次元 (404 × 548)
次元圧縮手法	特異値分解 非負値行列因子展開 オートエンコーダ
圧縮次元数	1 から 20 次元の各次元
評価指標	RMSE・差異

表-2 オートエンコーダモデルの学習条件

訓練データ	2400case
テストデータ	600case
学習回数	50 回
中間層の数	2 層 (256-128)
バッチサイズ	32
検証方法	交差分割

表-3 TCN・LSTM の学習条件

訓練データ	2400case
テストデータ	600case
説明変数	越流水深
目的変数	係数行列
学習回数	500 回 (損失が 10 回続くと早期終了)
中間層の数	LSTM 1 ブロック (64) TCN 4 ブロック (64) チャンネル数: 64 カーネルサイズ: 3 Global Average Pooling (GAP)
バッチサイズ	32
損失関数	平均二乗誤差
検証方法	交差分割

化した。その際、以下の式を用いた。

$$x_{\text{scaled}} = \frac{x - \mu}{\sigma} \quad (6)$$

ここで、 μ は平均、 σ は標準偏差を表す。説明変数と目的変数にはそれぞれ個別のスケイラーを適用した。

5. 実行条件・学習条件

本例題で行った次元圧縮の実行条件及び AE モデルと DNN モデルの各学習条件は表-1, 2 に示す。次元圧縮を用いた浸水域の復元に関する評価指標には 2 乗平均平方根誤差 (Root Mean Square Error; RMSE) を用いる。以下に RMSE・差異の式を示す。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - f_i)^2} \quad (5)$$

$$\text{差異} = a_i - f_i \quad (6)$$

なお、 n はデータ数、 a_i は復元された際の浸水深、 f_i はシミュレーションによる浸水深である。




図-6 RMSE と圧縮次元数の関係について




図-13 浸水域復元時間について

6. 学習結果

DNN で予測した係数行列を用いて各次元圧縮手法で復元した浸水域の結果を、復元精度と復元時間の観点から比較した。本章では、その結果を示す。

6.1 浸水域の予測精度

各次元圧縮手法における圧縮次元数と RMSE の関係を図-5 に示す。RMSE は全 3,000 ケースの平均値であり、実線は TCN、点線は LSTM による結果を表す。図-5 より、いずれの手法においても圧縮次元数の増加に伴い RMSE は単調に減少する傾向が見られ、特に 1~10 次元の範囲で顕著な低下が確認できる。各次元圧縮手法を比較すると、AE を用いた手法が全次元数にわたって最も低い RMSE を示した。AE は非線形な特徴抽出が可能であるため、SVD や NMF のような線形手法と比較して、複雑な浸水挙動を少ない次元数で的確に捉えられたと考えられる。一方、AE はさらなる精度向上に向けてパラメータの最適化を行う余地がある。時系列学習モデルの観点では、LSTM と TCN の RMSE はいずれの次元圧縮手法・圧縮次元数においても同程度の値で推移しており、両者の間に顕著な差異は認められなかった。このことから、本研究の予測タスクにおいては、ゲート機構を有する LSTM と拡張畳み込みを用いる TCN のいずれも同等の時系列モデリング能力を有していると言える。以上の結果より、約 22 万次元にのぼる高次元の浸水域データを 10 次元程度にまで大幅に圧縮して、高精度な浸水域予測が可能である。




図-8 Case A (越流地点 A) における浸水域のシミュレーション結果と復元結果の差異 (k は圧縮次元数.)

6.2 浸水域の予測時間

浸水域の予測に要した時間（係数行列の推論時間と復元時間の合計）を図-6 に示す．実線は TCN，点線は LSTM の結果である．図-6 より，TCN による予測時間は LSTM と比べて約 2 秒短縮でき，並列計算が可能な TCN の構造が寄与したと考えられる．また，次元圧縮手法では AE を用いた場合に最も時間を要する傾向が見られた．それでも最長でも約 5 秒であり，最大 212 秒を要する汎濫解析と比べて大幅な高速化が達成されている．AE は非線形な特徴抽出が可能なため，複雑な浸水挙動を低次元で的確に捉えられたと考えられる．ただし，AE のパラメータについては検討の余地がある．また，LSTM と TCN の RMSE は同程度で推移している．以上より，約 22 万次元の浸水域データを 10 次元程度に圧縮しても高精度な予測が可能であることが示唆される．

6.3 越流水深最大ケースの差異の可視化

越流水深最大ケースにおける差異の可視化結果を図-7 に示す．左が TCN を各次元圧縮手法に適用した結果，右が LSTM を各次元圧縮手法に適用した結果であり，括弧内は RMSE を表す．いずれの次元圧縮手法と深層学習手法の組み合わせでも差異は小さく，TCN と LSTM 間で RMSE の差は見られなかった．また，各次元圧縮手法の中では AE と深層学習手法を組み合わせた手法が最も低い RMSE を示す傾向が確認された．

7. おわりに

本研究は，多地点越流条件における浸水域予測を対象として，3 つの次元圧縮手法と 2 つの深層学習手法を組み合わせた手法を構築し，予測精度と計算効率の両面からその有効性を検討し，以下の結論を得た．

- 次元圧縮と深層学習を組み合わせることで，高精度

な予測が可能であり，予測精度と計算効率の両立が達成可能であることを確認した．

- 予測時間の観点では，TCN は LSTM と比べて係数行列の推論時間を約 2 秒短縮できることから，リアルタイム予測における TCN の有効性が示された．
- 本研究で採用した次元圧縮手法の中で，AE が最も高い精度を示し，約 22 万次元の浸水域データを 10 次元程度に圧縮しても高い予測精度を保持可能であることが確認された．

今後は，汎濫歴のある他河川での適用による妥当性の検証，より現実的な越流水深データを用いた実運用への適用可能性について検討する予定である．また，社会実装に向けては，降雨データを用いた河川水位予測モデルとの連携について検討する予定である．社会実装に向けては，降雨データを用いた河川水位予測モデルとの連携について検討する予定である．

参考文献

- 1) 中山龍也，山口敏太，一言正之，樫山和男：次元圧縮を適用した深層学習に基づくリアルタイム浸水域予測の高度化，AI・データサイエンス論文集 6 巻 3 号，p.287-295，2025．
- 2) Eckart, C., and Young, G. (1936). The approximation of one matrix by another of lower rank. *Psychometrika*, 1(3), 211-218.
- 3) Lee, D. D., and H. S. Seung. (1999), Learning the parts of objects by non-negative matrix factorization, *Nature* 401(6755), (October): 788-791.
- 4) Hinton, G. E., and Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504-507.
- 5) 一言正之，荒木光一，古木宏和：敵対的生成ネットワークによる洪水汎濫浸水域の推定，人工知能学会全国大会第 33 回，2019．
- 6) 国土地理院，基盤地図情報 <https://www.gsi.go.jp/kiban/> (参照 2023-10-10)

次元圧縮と深層学習を用いた浸水域予測における適用性評価

Applicability Assessment of Flood Inundation Area Prediction
Using Dimensionality Reduction and Deep Learning都市人間環境学専攻 1 年 山口 歓太
Kanta YAMAGUCHI

1. はじめに

これまで著者ら¹⁾は、荒川流域を対象として、次元圧縮と深層学習を用いたリアルタイム浸水域予測手法の構築と評価を行ってきた。本報告では、これまでに構築した同手法を、2015 年 9 月の関東・東北豪雨により大きな被害を受けた鬼怒川流域に適用し、異なる対象領域における本手法の適用性について検証する。さらに、国土地理院が公表する実測浸水形状との比較を通じて、実災害に対する本手法の適用可能性についても検討する。

2. 解析手法

本研究で提案する浸水域予測手法の概要を図-1 に示す。本手法は氾濫解析結果を学習データとし、次元圧縮と深層学習を組み合わせることで構築した。2 地点の越流・破堤シナリオに対する氾濫解析結果に次元圧縮を適用し、時系列水深を入力とする深層学習により係数を予測・復元することで、50 時間後の浸水域を高速に推定した。

本研究で用いた計算機環境は、CPU: Intel Core i7-14700F, GPU: NVIDIA GeForce RTX 4070 SUPER (12 GB) である。ソフトウェアは Python 3.10.13, TensorFlow 2.10.0, NumPy を用いた。

2.1 氾濫解析モデル

氾濫解析には Dynamic Wave 法を適用し、 x, y 方向の運動量保存式および質量保存式を式 (1) ~ (3) に示す。

$$\frac{\partial M}{\partial t} + \frac{\partial(uM)}{\partial x} + \frac{\partial(vM)}{\partial y} + gh \frac{\partial H}{\partial x} = -gh \frac{n^2 u \sqrt{u^2 + v^2}}{R^{4/3}} \quad (1)$$

$$\frac{\partial N}{\partial t} + \frac{\partial(uN)}{\partial x} + \frac{\partial(vN)}{\partial y} + gh \frac{\partial H}{\partial y} = -gh \frac{n^2 v \sqrt{u^2 + v^2}}{R^{4/3}} \quad (2)$$

$$\frac{\partial h}{\partial t} + \frac{\partial M}{\partial x} + \frac{\partial N}{\partial y} = 0 \quad (3)$$

ここで、 $M = uh$ 、 $N = vh$ は単位幅流量、 u, v は流速、 h は水深、 H は水位、 R は径深、 g は重力加速度、 n は粗度係数である。

2.2 解析対象領域

対象領域は、2015 年 9 月の関東・東北豪雨により大きな被害を受けた茨城県常総市周辺の鬼怒川流域であり、図-2 に示す。

標高および土地利用データには、国土地理院が提供する国土数値情報²⁾を用いた。解析は 25 m 格子で行い、




図-1: 本手法のフローチャート




図-2: 解析対象領域

格子数は 874×1076 である。

2.3 学習データ作成のための氾濫解析

学習データ作成のため、既往災害に基づき設定した 2 地点において、時系列の越流・破堤水深を与えた氾濫解析を実施した。また、地点 A は越流地点、地点 B は破堤地点とした。

越流条件の設定には、既往調査³⁾に基づく流量ハイドログラフを用いた。ここで、流量ハイドログラフの時系列を $Q(t)$ 、そのピーク値を Q_p とし、次式により無次元化した。

$$\frac{Q(t)}{Q_p} = q^*(t) \quad (4)$$

流量 $Q(t)$ と越流水深 $h(t)$ の関係には越流公式を用い、次式で表されるものとした。

$$Q = CBh^{3/2} \quad (5)$$

ここで、 C は流出係数、 B は流出幅である。 C は 1.55、 B は 200 m とし、越流・破堤のいずれの場合においても同一の値を入力し、時間的に一定とした。式 (5) を用い

ることで、無次元流量 $q^*(t)$ から流出水深の時系列 $h(t)$ は次式で与えられる。

$$h(t) = h_p \cdot [q^*(t)]^{2/3} \quad (6)$$

ここで、 h_p はピーク水深であり、 $h(t)$ は h_p と $[q^*(t)]^{2/3}$ の積として与えられる。ピーク水深 h_p は、様々な被害規模を学習データに含めるため、0.1～3.0 m の範囲で一様乱数により設定した。以上により、流量ハイドログラフを水深ハイドログラフへ変換した。

入力条件として、1～40 時間の越流・破堤水深時系列を与え、最大 50 時間まで氾濫計算を行った。以上の条件により、深層学習モデルの学習用データとして 1000 ケースの氾濫計算結果を作成した。さらに、実災害に対する適用性を検証するため、これら 1000 ケースを用いて学習したモデルの重みを保存し、再現計算に基づく推定入力水深を 1 ケース分設定した。この推定入力水深は学習には用いず、保存した学習済みモデルに入力することで、50 時間後の浸水深分布を予測した。既往調査による代表ケースおよび、1000 ケース中でピーク水深が最大となるケースを図-3 に示す。

本研究では、構築した予測手法に対して、以下の 2 種類の検証を行った。

検証 1 では、学習データとして作成した 1000 ケースを対象に、予測浸水深分布の精度および予測時間を評価した。

検証 2 では、再現計算に基づく推定入力水深を 1 ケース分入力し、得られた予測浸水域を実測浸水形状と比較することで、実災害に対する適用性を検証した。

3. 次元圧縮手法および深層学習手法

次元圧縮は、多次元データを低次元に変換し、情報を保持しつつ計算負荷を軽減する手法である。本研究では、浸水解析によって得られた浸水深データに対して特異値分解 (Singular Value Decomposition: SVD) を適用し、次元圧縮を行った。得られた係数行列を深層学習モデルの目的変数とし、越流・破堤水深の時系列データから将来の浸水深分布を予測する手法を構築した。

3.1 特異値分解

次元圧縮手法の 1 つである特異値分解 (SVD) は、行列を複数の特異ベクトルとそれに対応する特異値に分解する手法である。SVD は以下の式で表され、 $n \times m$ の行列 A は次のように分解される。

$$A = U \Sigma V^T \quad (1)$$

ここで、 U は左特異ベクトル行列、 Σ は特異値を対角成分に持つ対角行列、 V^T は右特異ベクトル行列の転置行列である。各行列は以下のように表される。

$$U = \begin{pmatrix} u_{1,1} & \cdots & u_{1,m} \\ \vdots & \ddots & \vdots \\ u_{m,1} & \cdots & u_{m,m} \end{pmatrix} = (\vec{u}_1 \ \vec{u}_2 \ \cdots \ \vec{u}_m) \quad (2)$$




図-3: 越流・破堤水深の概形

$$\Sigma = \begin{pmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_r \end{pmatrix} \quad (3)$$

$$V^T = \begin{pmatrix} v_{1,1} & \cdots & v_{1,n} \\ \vdots & \ddots & \vdots \\ v_{n,1} & \cdots & v_{n,n} \end{pmatrix} = (\vec{v}_1 \ \vec{v}_2 \ \cdots \ \vec{v}_n)^T \quad (4)$$

ここで、 σ_i は特異値を表し、対応する特異ベクトル $\vec{u}_i$ および $\vec{v}_i$ が行列 A の特徴を構成する。特異値が大きいほど、浸水深分布における重要な空間構造を強く反映していることを意味する。

本研究では、特異値の大きい順に上位 k 個の成分のみを抽出し、それらに対応する係数を低次元表現として採用した。これにより、浸水深分布の主要な特徴を保持したまま、データ次元を大幅に削減することが可能となる。SVD によって得られた係数行列は、浸水深分布を再構成するための情報を集約したものであり、本研究ではこれを深層学習モデルの目的変数として用いた。

3.2 深層学習手法

本報告では、1 時間ごとの越流・破堤水深を入力とし、各ケースの係数を出力とする深層学習モデルを構築した。深層学習手法には、時系列データの扱いに適した RNN (Recurrent Neural Network) を用いた。入力は 2 地点の越流・破堤水深 (1 時間間隔、1～40 時間) とし、出力は SVD 係数とした。予測された係数から復元計算を行い、50 時間後の浸水深分布を推定した。

なお、検証 1 では学習データとして作成した各ケースの入力水深を用いて推論を行ったのに対し、検証 2 では、1000 ケース学習で得られたモデルを用い、再現計算に基づく推定入力水深を入力として 50 時間後の浸水深分布を推定した。

4. 実行条件と評価指標

SVD および RNN の学習・実行条件を表-1 に示す。

検証 1 では、1000 ケースを対象とした予測精度評価のため、評価指標として RMSE (Root Mean Square Error) を用いた。RMSE は下記式で表される。

表-1: SVD および RNN の条件

区分	項目	内容
SVD	対象データ	50 時間後の氾濫域
	データ数	1000 case
	入力次元数	940,424 (874 × 1,076)
	圧縮次元数	1~30 次元
RNN	訓練 / テストデータ	800 / 200 case
	入力 / 出力データ	越流・破堤水深 (1~40 時間) → 係数行列
	学習回数	最大 500 回
	中間層の数	1 層 (64 ユニット)
	バッチサイズ	32
	損失関数	平均二乗誤差 (MSE)
	検証方法	交差検証




図-4: 検証 1 における圧縮次元数と RMSE




図-5: 検証 1 における圧縮次元数と予測時間

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - f_i)^2} \quad (5)$$

ここで、 n はデータ数、 a_i は復元された浸水深、 f_i はシミュレーションにより得られた浸水深である。

一方、検証 2 では、推定入力水深を用いて得られた予測浸水域と実測浸水域の重なりを評価するため、IoU (Intersection over Union) を用いた。IoU は、予測領域を A 、正解領域を B とすると、次式で定義される。

$$\text{IoU}(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (6)$$

ここで、IoU 値が大きいほど、予測浸水域と実測浸水域の一致度が高いことを示す。

5. ケーススタディ結果

本章では、提案手法に対する 2 種類の検証結果を示す。検証 1 では、1000 ケースを対象として予測精度および予測時間を評価する。検証 2 では、再現計算に基づく推定入力水深を用いた予測結果を、実測浸水形状と比

較することで実災害への適用性を検証する。

5.1 検証 1：1000 ケースに対する予測精度および予測時間の評価

圧縮次元数と RMSE の関係を図-4 に、圧縮次元数と予測時間 (RNN による推論時間と SVD による復元時間の和) の関係を図-5 に、ピーク水深最大ケースにおける浸水深分布の可視化結果を図-6 に示す。

5.1.1 予測精度の評価

RMSE は圧縮次元数の増加に伴い全体として低下する傾向を示しており、低次元では浸水深分布の再現精度が不十分である一方、圧縮次元数を増加させることで予測精度が向上することが確認できる。特に、圧縮次元数が 10 次元程度以上となると、RMSE の低下は緩やかとなり、高精度な予測結果が安定して得られた。

この結果は、浸水深分布に内在する主要な空間構造が、比較的少数の特異成分によって表現可能であることを示唆している。すなわち、SVD による次元圧縮を通じて、物理的に重要な浸水挙動を保持したまま、効率的な低次元表現が実現できていると考えられる。

5.1.2 予測時間の評価

ここでの予測時間は、RNN による推論時間と、予測された係数を用いた SVD 復元計算時間の和として定義した。その結果、いずれの圧縮次元数においても、予測時間はおおむね 2~3 秒程度に収まっており、圧縮次元数の増加に対して大きな増加は見られなかった。

このことから、本研究で構築した予測手法は、高精度な浸水深分布の推定を高速に実行可能であり、リアルタイム予測や即時的な防災判断への適用に十分な計算性能を有していることが確認された。

5.2 検証 2：推定入力水深を用いた実測浸水形状との比較

本節では、検証 2 として、再現計算に基づく推定入力水深を 1 ケース分入力し、得られた予測結果を実測浸水形状と比較した結果を示す。実測浸水形状⁴⁾を図-7 に示す。また、実測 1 ケースを対象とした圧縮次元数と RMSE の関係を図-8 に、圧縮次元数と予測時間の関係を図-9 に示す。さらに、氾濫解析結果と RNN-SVD による予測結果の比較を図-10 に示す。

再現計算に基づく推定入力水深を 1 ケース分入力し、実測浸水形状との比較を行った。図-8 より、実測 1 ケースに対しても RMSE は小さく、浸水深分布を概ね良好に推定できることが確認された。また、図-9 より、予測時間は圧縮次元数に対して大きく変化せず、実測入力に対しても高速な推定が可能であることがわかる。

一方、図-10 より、予測結果は氾濫解析結果と概ね類似した浸水深分布を示したが、浸水範囲は実測浸水形状と比較してやや大きくなる傾向が見られた。

さらに、実測浸水形状との一致度を IoU により評価した結果、氾濫解析結果の IoU は 79.86%、RNN-SVD




図-6: 検証 1 における浸水深の可視化結果



図-7: 検証 2 における実測浸水形状




図-8: 検証 2 における実測 1 ケースの圧縮次元数と RMSE

(10 次元) の IoU は 79.38% となった。このことから、推定入力水深を用いた場合においても、本手法は実測浸水形状に対して 8 割程度の一致を示し、実災害への適用可能性を有することが示唆された。

6. 結論

本報告では、荒川流域を対象として構築してきた浸水域予測手法を鬼怒川流域に適用し、異なる対象領域における適用性を検証した。その結果、検証 1 より、1000 ケースを対象とした場合には、10 次元程度以降において高精度かつ高速な浸水域予測が可能であることを確認した。さらに、検証 2 より、推定入力水深を用いた実測浸水形状との比較においても、IoU 値の観点から 8 割程度




図-9: 検証 2 における実測 1 ケースの圧縮次元数と予測時間




図-10: 検証 2 における氾濫解析結果と予測結果の比較

の一致が得られ、実災害への適用可能性が示された。今後は、他の次元圧縮手法の適用や、実測値とのさらなる比較検証を行う予定である。

参考文献

- 1) 中山 龍也, 山口 欽太, 一言 正之, 檜山 和男: 次元圧縮を適用した深層学習に基づくリアルタイム浸水域予測の高度化, AI・データサイエンス論文集, 第 6 巻, 第 3 号, 2025.
- 2) 国土地理院: 国土数値情報, <https://www.gsi.go.jp/kiban/> (参照日: 2023 年 10 月 10 日).
- 3) 土木学会・地盤工学会合同調査団関東グループ: 平成 27 年 9 月関東・東北豪雨による関東地方災害調査報告書, 土木学会, 2016.
- 4) 国土地理院: 平成 27 年 9 月関東・東北豪雨の情報, 国土交通省国土地理院ホームページ, <https://www.gsi.go.jp/BOUSAI/H27.taihuu18gou.html>

点群データを用いた粗度係数算出手法におけるドメインギャップの 定量化と他地域への適用性検証

Quantification of Domain Gap and Regional Applicability Verification in Roughness Coefficient Estimation Using 3D Point Cloud Data

修士1年 大舘 雄介
Yusuke ODATE

1. はじめに

従来の浸水シミュレーションでは、土地利用項目による粗度係数を用いてきたが、詳細な地形情報を考慮できていないという課題があった¹⁾。前報⁵⁾では、点群データから粗度係数を算出し浸水シミュレーションに適用する手法を提案し、サブグリッドスケールを導入することで PointNet+ サブグリッドが最高精度 (IoU 87.3%) を達成することを示した。しかし、学習データ (米国室内実験水路) と千曲川 (日本・都市規模) との間のドメインギャップの機構的説明、および他地域への汎用性検証は不十分であった。本報告では、このドメインギャップを nZ 正規化と Test-Time Batch Normalization (TTBN) により定量化・補正する手法を提案する。また、点群データが存在しない鬼怒川流域に対して U-Net による点群生成を行い、浸水シミュレーションへ適用することで手法の地域汎用性を検証する。

2. 対象地域・データ

2.1 千曲川流域

メインの検証対象は長野県千曲川流域とした (図-1)。本地域は令和元年 10 月に台風 19 号による浸水被害が生じた地域であり、前報と同一の対象地域である。点群データは信州砂防情報マップより取得し、4 点/m² 以上で整備されている。浸水実績図および土地利用情報は国土数値情報より参照した。

2.2 鬼怒川流域

参考値としての検証対象に茨城県鬼怒川流域を用いた (図-2)。本地域は平成 27 年 9 月に台風 18 号による浸水被害が生じた地域であり、浸水時系列データが整備されている。点群データが存在しないため、後述する U-Net による生成点群を使用した。

3. 粗度係数算出手法の概要

本節では前報⁵⁾で用いた各手法を簡潔に述べる。

3.1 Strickler 式・GSRA 的手法

Strickler 式²⁾はメッシュ内の点群高度分布から標準偏差 σ 、四分位範囲 IQR、平均絶対偏差 MAD を用いて粗度係数 n を算出する (式 (1)–(2))。GSRA 的手法³⁾はさらに地形複雑度指標 C_{idx} を加えることで地形の空間的複雑さを粗度に反映する (式 (3), (4))。

$$R = \sqrt{0.7\sigma^2 + 0.2\text{IQR}^2 + 0.1\text{MAD}^2} \quad (1)$$




図-1 千曲川流域 対象地域 (航空写真 (左), 標高図 (右))




図-2 鬼怒川流域 標高図 (U-Net 生成点群より作成)

$$k_s = 2.5R, \quad n = 0.034 k_s^{1/6} \quad (2)$$

$$C_{idx} = 1.0 + \tanh \frac{\sigma}{\mu} \quad (3)$$

$$n = 0.025 \times \left(2.0 \times \frac{R}{0.05} \right)^{\frac{1}{6}} \times (0.8 + 0.2(C_{idx} - 1.0)) \quad (4)$$

3.2 PointNet 活用手法とサブグリッドスケール

Haces-Garcia et al.¹⁾の事前学習済み PointNet モデルを用いて点群から直接粗度係数を推論する。モデルの適用スケールは 1m メッシュであるため、25m メッシュに対してはサブグリッドスケール処理 (図-3) を導入した。1m サブグリッド毎に推論した粗度係数を power-mean 縮約 (式 (5)) により統合する。

$$n_{\text{eff}} = \left(\frac{1}{N} \sum_{i=1}^N n_i^{1.5} \right)^{2/3} \quad (5)$$




図-3 サブグリッドスケールの概略図

表-1 前報における各手法の IoU 値 (千曲川, 25m)

手法	IoU 値 (%)
土地利用分類	86.40
Strickler 式+サブグリッド	86.93
GSRA 的手法+サブグリッド	86.36
PointNet +サブグリッド	87.32

3.3 各手法の比較

前報⁵⁾における千曲川での IoU 値を表-1 に示す。Strickler 式は砂粒スケールに近い細粒地形, GSRA 的手法はなだらかな丘陵地形, PointNet は都市スケールの複雑な地物形状の捕捉にそれぞれ有効である。サブグリッドスケールの導入によりいずれの手法でも精度が改善され, 特に PointNet+ サブグリッドが最高精度 (87.32%) を達成し, 土地利用分類 (86.40%) を上回った。

4. PointNet のドメインギャップ定量化と TTBN

4.1 ドメインギャップの定量化

PointNet モデルは米国室内実験水路 (幅 0.6 m, 長さ 12 m) で取得した点群を教師データとして学習されている。学習データにおける地上相対高さ (nZ) の 95 パーセンタイル値は約 0.05 m であるのに対し, 千曲川点群では 4.37 m であり, 約 87.4 倍のスケール差が存在する。このスケール差が浸水シミュレーション精度に与える影響を定量的に評価するため, nZ 正規化および TTBN を導入した。

4.2 nZ 正規化

nZ 正規化は, 点群の絶対標高 z_{abs} から 5m 解像度 DEM 地面標高 z_{DEM} を減算することで, 地形の傾斜・標高の影響を除去し, 純粋な地物の凹凸のみを評価する (式 (6))。

$$nZ = z_{\text{abs}} - z_{\text{DEM}} \quad (6)$$

4.3 Test-Time Batch Normalization (TTBN)

TTBN はテスト時に Batch Normalization (BN) 層の running_mean および running_var を推論対象ドメインの点群で更新する手法である⁶⁾。重みパラメータは一切変更せず, BN 統計のみを更新することで, ラベルなし現地地点群のみによるドメイン適応が可能となる。本報




図-4 BN 統計シフト量 (上: running_mean, 下: running_var)

表-2 千曲川 各手法の IoU 値

手法	IoU 値 (%)
土地利用分類	86.40
PointNet	86.92
PointNet +サブグリッド	87.32
PointNet +サブグリッド+ nZ	87.00
PointNet + SG + nZ + TTBN (1 回目)	87.72
PointNet + SG + nZ + TTBN (2 回目)	87.45
PointNet + SG + nZ + TTBN (3 回目)	87.00
PointNet + SG + nZ + TTBN (平均)	87.39
※ SG: サブグリッド	

告では千曲川 LAS ファイルから 5,000 サブグリッドを収集し, 5 エポック・モメンタム 0.1 で BN 統計を更新した。

4.4 BN 統計シフトの分析

TTBN 前後の BN 統計シフト量を図-4 に示す。PointNet は 5 層の BN 層 (Layer 0-4) を持ち, Global Max Pooling 直後の全結合層 (Layer 3, 512 チャンネル) において running_mean の絶対変化量が 13.98, running_var の絶対変化量が 1029.7 と突出して大きいことが確認された。Layer 3 は点群全体の大域的特徴が集約される層であり, 87.4 倍の nZ スケール差がこの層に最も集中することを示している。

4.5 千曲川における IoU 評価

各条件での IoU 値を表-2 に示す。また代表的な粗度係数マップを図-5 に示す。TTBN 導入により 1 回目で 87.72% を達成し, 前報最高値 (PointNet+ サブグリッド: 87.32%) を更新した。ただし TTBN のサンプリングにランダム性があるため, 3 回の実行平均は 87.39% (標準偏差 ± 0.36%) であり, サンプリングのばらつきが残ることが課題である。

5. 鬼怒川への適用

5.1 U-Net による点群生成

鬼怒川流域には LiDAR による点群データが存在しないため, U-Net を用いて標高データから点群を生成した。荒川・千曲川の実 LiDAR 点群と対応する標高データのペアを学習データとし (タイル総数 25,185 枚), ス




図-5 千曲川 粗度係数マップ比較 (左: PointNet+ サブグリッド, 右 1-3 回目: nZ+TTBN)




図-6 U-Net 点群生成フロー (荒川・千曲川 LiDAR を学習し鬼怒川標高から点群を生成)

キップ接続を持つ TerrainUNetV2 を 100 エポック学習した (図-6)。損失関数には MAE と SSIM を組み合わせた CombinedLoss (MAE 60%+SSIM 40%) を用いた。生成された鬼怒川点群の標高平均は 19.43 m であり、実測値 (18.49 m) と近似した妥当な値が得られた (図-7)。

5.2 生成点群の適用制約

生成点群は標高データの超解像であるため、地面点と地物点の区別がなく、nZ 正規化の適用が困難である。診断の結果、生成点群の nZ p95 は 19.58 m と千曲川実 LiDAR (4.37 m) に比べて著しく大きく、これは地形の微細起伏が DEM 地面標高との差として現れるためである。したがって鬼怒川への適用では、PointNet+ サブグリッドのみを用い、nZ 正規化および TTBN は適用しない。これを参考値として位置づける。

5.3 鬼怒川浸水シミュレーション結果

各時刻における浸水シミュレーション結果の IoU 値を表-3 に示す。PointNet+ サブグリッドはいずれの時刻においても従来の土地利用分類を上回る精度を示した。特に 530 分後 (浸水発展途中) において PointNet+ サブグリッドは 66.98% を達成し、従来比で最大 +2.01




図-7 U-Net 生成点群による鬼怒川標高図

表-3 鬼怒川 各手法の IoU 値

手法	530 分 (%)	1680 分 (%)	1860 分 (%)
土地利用	64.97	81.97	80.59
Strickler + SG	66.21	82.15	80.76
GSRA + SG	64.25	81.97	80.58
PointNet + SG	66.98	82.41	80.99
※ SG: サブグリッド			

ポイントの向上が確認された。1680 分後および 1860 分後においても他の点群手法と同等以上の精度を維持しており、U-Net 生成点群を用いた場合においても点群由来の粗度係数が土地利用分類を一貫して上回ることが示された。

6. 考察

6.1 各手法の比較と特性

千曲川における水際線の可視化を図-8 に示す。Strickler 式はメッシュ内の高度分布から粗度を算出するため、砂粒スケールに近い細粒地形では有効であるが、都市的な地物形状の反映には限界がある。GSRA 的手法は地形複雑度指標 C_{idx} を加えることで丘陵地形のなだらかな起伏を捉えやすいが、サブグリッド導入後も精度向上は限定的であった。PointNet は点群の 3 次元形状を直接処理するため、建物・植生等の複雑な地物を粗度に反映できる点で優位性を持ち、サブグリッドとの組み合わせで最高精度を達成した。

6.2 TTBN の効果と限界

TTBN は Layer 3 の BN 統計を大幅にシフトさせること ($\Delta \text{var} \approx 1030$) でドメインギャップを補正し、最大 +0.40% の IoU 向上を実現した。一方、3 回実行の標準偏差 $\pm 0.36\%$ は TTBN による平均改善量 +0.07% と同程度であり、サンプリング由来のばらつきが有意な効果を統計的に示すことを困難にしている。TTBN の安定化、例えばメモリに蓄積した統計で大バッチ相当の BN 更新を行う MemBN 的アプローチが今後の課題である。




図-8 千曲川 水際線の可視化 (360 分後, 各手法比較)




図-9 鬼怒川 水際線の可視化 (530 分後, 各手法比較)

6.3 手法の地域汎用性

鬼怒川における 530 分後の水際線を図-9 に示す。実 LiDAR なしで U-Net 生成点群のみを用いた場合でも、PointNet+ サブグリッドが土地利用分類を上回ることを示した。浸水発展途中 (530 分後) では差が顕著であり、粗度係数が浸水の時空間的な発展に影響することが確認された。千曲川では最大浸水域での評価であったのに対し、鬼怒川では発展途中の段階でも点群由来の粗度が有効に機能することが示された点で、手法の汎用性を補強する知見となった。

6.4 点群品質と精度の関係

千曲川のオープンソース点群に対してコードによる品質解析を実施した結果を図-10 に示す。低品質地点では点密度が $1\sim 2$ 点/ m^2 程度と低く、非地面点の割合が $76\sim 84\%$ に達することが確認された。Haces-Garcia et al.¹⁾ は点群品質が精度に影響することを指摘しており、こうした密度の不均一性が TTBN のサンプリングばらつきの一因となっている可能性がある。今後は品質の低い地点へのドローン計測による高密度点群の取得を検討する。




図-10 点群品質解析の例 (上: 高品質地点, 下: 低品質地点)

7. 結論

本報告では以下の結論を得た。

- 学習データと千曲川との間に 87.4 倍の nZ スケール差が存在し、これが Layer 3 (Global Max Pooling 直後) の BN 統計に集中的に現れることを定量化した。
- TTBN により BN 統計を現地点群で更新することで、前報最高値 (87.32%) を上回る 87.72% (1 回目) を達成した。ただしサンプリングのばらつき ($\pm 0.36\%$) が課題として残る。

今後は、ランプリングのランダム性によるばらつきをなくすために、サンプリングの安定化を図る。

参考文献

- 1) Haces-Garcia, F., Kotzamanis, V., Glennie, C. L. and Rifai, H. S.: Improving Manning's n in Flood Models Using 3D Point Clouds, Flume Experiments, and Deep Learning, Water Resources Research, Vol. 61, No. 3, e2024WR037665, 2025.
- 2) Fenton, J. D.: Calculating resistance to flow in open channels, Alternative Hydraulics Paper 2, <http://johndfenton.com/Alternative-Hydraulics.html>, 2010.
- 3) Amatulli, G., McInerney, D., Sethi, T., Strobl, P., and Domisch, S.: Geomorpho90m, empirical evaluation and accuracy assessment of global high-resolution geomorphometric layers, Scientific Data, 7, 162, <https://doi.org/10.1038/s41597-020-0479-6>, 2020.
- 4) 武田 誠・佐藤 大介・曾根原 真秀・豊田 政史・川池 健司 (2022): 破堤条件および建物の影響を考慮した千曲川における氾濫解析の精度評価, 土木学会論文集 B1 (水工学), Vol.78, No.2, pp.799-804.
- 5) 大館 雄介 (2026): サブグリッドスケール効果の導入による点群からの粗度係数算出手法の妥当性向上の検討, 第 5 回計算力学研究室発表会.
- 6) Schneider, S., Rusak, E., Ecker, A. S. and Bethge, M.: Improving robustness against common corruptions by covariate shift adaptation, Advances in Neural Information Processing Systems, Vol. 33, 2020.

XREAL を用いたデジタルマーカーベース手法に基づく MR 可視化システムの構築

Development of an MR Visualization System
Based on a Digital Marker-Based Approach Using XREAL

都市人間環境学専攻 博士課程前期 1 年 石川 隼也
Shunya ISHIKAWA

1. はじめに

近年、複合現実感 (Mixed Reality, 以後 MR) 技術や拡張現実感 (Augmented Reality, 以後 AR) 技術は様々な分野で活用され、その有用性が広く認められている。建設分野においても、計画・設計・施工・維持管理の各プロセスに適用され、合意形成の促進や生産性・安全性の向上、業務効率化に寄与している¹⁾。屋外における重畳手法は、画像認識型のマーカーベース手法と位置認識型のロケーションベース手法に大別される。

中祖ら²⁾は、両手法を複合したハイブリッド手法を提案し、各環境において誤差数 cm 程度の高精度な重畳を実現した。しかし、洋上でのマーカー設置は依然として困難であり、また専用の測位受信機は高価かつ大型であるため、土木現場での実用性に課題があった。

そこで本論文では、取得した位置情報と関連付けたデジタルマーカーをデバイス画面に表示することで、物理的なマーカー設置を不要とするマーカーベース型の MR 可視化システムを構築した。本システムでは、利用者が移動すると現在位置に最も近いマーカーが自動的に切り替わる仕組みを採用しており、広範囲にわたる MR 可視化を連続的に実施することができる。本システムは、スマートグラス XREAL Air2 Ultra (以降, XREAL) と iPad Pro 13-inch (M4) (以降, iPad Pro) を組み合わせて構成し、高価な専用測位受信機を用いることなく屋外での高精度な重畳を目指した。XREAL はメガネ型のスマートグラスであり、ヘルメット着用が義務付けられる土木工事現場においてもヘルメット下への装着が可能のため、HMD 型デバイスと比較して高い実用性を有する。本システムの有用性を検証するため、河川流れへの適用を行った。

2. MR 可視化システム概要

本システムのフローチャートを図-1 に示す。

2.1 開発環境

本研究では、統合開発環境として Unity 6000.1.7f1, 開発キットとして Mixed Reality Toolkit 3³⁾を使用した。使用デバイスは、マーカー表示用に iPad Pro 13-inch (M4), MR 可視化用に XREAL 社製スマートグラス XREAL Air2 Ultra である。XREAL 上の操作には Mixed Reality Toolkit 3 のハンドトラッキング機能を採用し、操作者の手指の動きをリアルタイムに認識・追跡することで、コントローラーレスでの仮想オブジェクト操作を実現した。なお、操作者の位置情報は iPad Pro により




図 - 1 MR 可視化システムのフローチャート



図 - 2 iPad Pro の画面 UI

取得した。

2.2 iPad Pro 側のプリプロセス

iPad Pro 側のプリプロセスでは、使用するマーカーおよび UI の設定を Unity 内で行う。図-2 に iPad Pro の画面 UI を示す。表示項目は、取得位置情報、デバイスの傾き、各マーカーまでの距離、および方位角であり、それぞれの詳細は後述する。

2.3 iPad Pro 側のメインプロセス

2.3.1 位置情報の取得

位置情報の取得には、iPad Pro に標準搭載された GPS 機能を利用した。本デバイスで取得される位置情報の精度は、誤差数メートル程度である。

2.3.2 マーカーの選択・表示

各マーカーには、対応する現実空間の位置情報（緯度、経度、標高）を予め付与する。デバイスが取得した位置情報と各マーカーの位置情報との距離を算出し、最もデバイスに近いマーカーを画面に表示する。

可視化対象を正しい向きに重畳するためには、マーカーを常に一定の向きに表示する必要がある。しかし、利用者自身がデバイスの向きを常に正しく保つことは困難である。そこで、デバイスのコンパス機能から真北となす方位角を取得し、その値の分だけマーカーを逆回転させることで、利用者の向きによらずマーカーを北向きに表示する。

方位角と同様に、仰俯角が不適切な場合も高精度な重畳は実現されない。本システムでは、デバイスに搭載された加速度センサーにより仰俯角を算出し、デバイスの傾きに応じてマーカーを3軸で回転させる機能を導入した。図-3に示すように、デバイスには常に鉛直方向に重力加速度が作用するため、デバイスの画面を xy 平面、奥行き方向を z 軸とした座標系において各軸成分に分解することで、各軸の傾きを定量的に把握できる。各軸の傾き成分は-1から1の範囲で正規化される。具体的な補正手順を以下に示す。

1. 加速度センサーにより、各軸成分の重力加速度（-1.0～1.0）を取得する。
2. デバイス水平時の各軸値（ $x, y, z = 0.0, 0.0, -1.0$ ）との差を算出する。
3. 算出した差に -90° を乗じ、補正値を算出する。
4. 補正値に応じてマーカーを3軸で回転させる。

2.3.3 位置情報更新・マーカー変更

位置情報が更新されるたびに、デバイスの現在位置と各マーカーの位置情報との距離を算出し、最もデバイスに近いマーカーへ切り替える。

2.4 XREAL 側のプリプロセス

XREAL 側のプリプロセスでは、可視化モデルおよび UI の設定を Unity 内で行う。本システムでは、重畳精度の向上を目的として、可視化モデルを手動で移動・回転できる UI を導入した。空間座標系（ x, y, z ）の6自由度での補正に対応しており、詳細は文献⁴⁾を参照されたい。

2.5 XREAL 側のメインプロセス

2.5.1 マーカー認識・MR 可視化

XREAL は、iPad Pro の画面に表示されたマーカーを認識することで MR 可視化を実施する。

2.5.2 可視化位置補正・マーカー変更

可視化位置の補正は、デバイスのカメラが取得する周囲の特徴点をトラッキングすることで行われる。また、iPad Pro に表示されるマーカーが切り替わるたびに、XREAL によるマーカーの再認識が実施される。

2.6 XREAL 側のポストプロセス

前述の UI による手動補正を施すことで、可視化モデルを正確な位置に重畳することが可能となる。




図-3 マーカーの仰俯角補正




図-4 精度検証実施環境

3. 適用例

3.1 位置情報の精度検証

iPad Pro で取得した位置情報の精度を検証した。

3.1.1 実施環境

検証地点は東京都文京区に位置する基準点（文3-H28094）とした。図-4に示すように、地面から高さ1.0 m の位置に iPad Pro を水平に設置し、基準点の既知座標（緯度 35.702912778°，経度 139.7511290278°）と iPad Pro で取得した緯度・経度を比較した。位置情報は1秒間隔で最大1時間取得した。

3.1.2 検証結果

取得開始から約 2500 s 経過後、位置情報の更新が停止したため検証を終了した。緯度・経度の実測値は、図-5に示すように基準点を中心として概ね均等に分布していた。標準偏差は緯度 0.00034°，経度 0.00035° であり、距離換算するとそれぞれ約 3.75 m, 3.05 m であった。また、図-6、図-7に緯度・経度それぞれの実測値と基準点値との差分の時系列変化を示す。いずれの成分においても、時間経過に伴う差分の収束傾向は認められなかった。

以上より、iPad Pro で取得した位置情報には約 3 m の誤差が生じることが明らかとなった。事前設置するマーカー間隔を 3 m とすることで、不要なマーカー数を抑制し、アプリケーションのデータ容量削減が期待できる。




図 - 5 実測値の緯度・経度




図 - 6 実測値の誤差（緯度）




図 - 7 実測値の誤差（経度）

3.2 河川流れへの適用

本システムを河川流れに適用し、その有用性を検証した。

3.2.1 実施環境

適用場所は図-8⁵⁾に示す東京都文京区後樂園に位置する小石川橋とした。可視化対象は神田川の河川流れのモデルである。モデルの詳細は文献⁶⁾を参照されたい。本適用では、現実空間の緯度、経度および標高を付与したマーカーを3点設置した。

3.2.2 適用結果

図-9に手動補正前、図-10に手動補正後の地点Bにおける重畳結果を示す。デジタルマーカーを用いることで、概ね正しい位置へのモデル重畳が可能であることを確認




図 - 8 可視化実施環境



図 - 9 可視化結果：手動補正前




図 - 10 可視化結果：手動補正後

した。さらに、手動補正を施すことで重畳精度が向上することを確認した。

以上より、物理的なマーカー設置が困難な洋上等においても、専用の測位受信機を用いることなく高精度な重畳が実現可能であることが示され、本システムの有用性が確認された。

3.2.3 デジタルマーカー設置間隔の検討

本項では、マーカー設置間隔が重畳精度に与える影響を検証した。図-8⁵⁾の地点 AB 間を 4 等分する位置に、図-11に示すようにマーカー D, E, F を設置した。可視化位置は各マーカー間の midpoint とした。間隔 12m の検証ではマーカー A, B のみを設置して midpoint E で、間隔 6m の検証では追加でマーカー E を設置して midpoint D で、間隔 3m の検証では追加でマーカー D を設置して地点 AD の midpoint でそれぞれ可視化を行った。本システムでは位置情報に




図 - 11 各マーカーの間隔



図 - 12 可視化結果：マーカー間隔 12m



図 - 13 可視化結果：マーカー間隔 6m



図 - 14 可視化結果：マーカー間隔 3m

に基づき最も近いマーカーを選択するため、AB間の中点（地点E）ではマーカーB、AE間の中点（地点D）ではマーカーE、AD間の中点ではマーカーAがそれぞれ選択された状態で可視化を行った。各間隔における可視化

結果をそれぞれ図-12（12m）、図-13（6m）、図-14（3m）に示す。間隔12mの場合、他の2条件と比較して重畳精度が低下することを確認した。一方、間隔3mと6mの間では重畳精度に有意な差は認められなかった。以上より、本システムに適したマーカー設置間隔は3～6m程度であると判断される。

4. おわりに

本発表では、物理的なマーカー設置が困難な環境においてもマーカーベース手法を適用可能とし、外部の測位受信機を用いることなく屋外で高精度な重畳を実現することを目的として、デバイスが取得する位置情報に基づくデジタルマーカーベース型MR可視化システムを構築した。河川流れの可視化への適用を通じて有用性を検証し、以下の結論を得た。

- iPad Proで取得した位置情報には約3mの誤差が生じることを確認した。
- 物理的なマーカー設置が困難な洋上等においても、専用の測位受信機を用いることなく、概ね高精度な重畳が実現可能であることを確認した。また、手動補正を施すことで、重畳精度がさらに向上することを確認した。
- マーカー設置間隔の検討により、間隔12mでは重畳精度が低下する一方、3mと6mの間では有意な差が認められないことを確認した。以上より、本システムに適したマーカー設置間隔は3～6m程度であり、データ容量の削減を考慮すると、位置情報誤差の許容範囲内でマーカー間隔はなるべく大きくすることが望ましい。

今後は、多地点での検証を実施するとともに、より広範な環境への適用を通じて、本システムの実用性をさらに検討する予定である。

参考文献

- 1) 矢吹信喜：土木分野におけるVR/ARの活用に関する研究と実務への適用、計測と制御、Vol.55, No.6, pp.483-488, 2016.
- 2) 中祖諒大，檜山和男，大原幸大，琴浦毅：ロケーションベースとマーカーベースの手法を用いたハイブリッドMR可視化システムの構築，土木学会論文集，81巻，22号，24-22008，2025.
- 3) Microsoft：MR TK3，〈<https://learn.microsoft.com/>〉，（入手2025.12.16）.
- 4) 鈴木雅大，大川博史，中祖諒大，檜山和男：小型GNSS受信機を用いた水域環境におけるAR可視化システムの構築，土木学会論文集，79巻，22号，22-22013，2023.
- 5) 国土地理院：地理院地図，〈<https://maps.gsi.go.jp/>〉，（入手2025.12.16）.
- 6) 花立麻衣子，菅田大輔，檜山和男，宮地英生，前田勇司，西畑剛：水環境流れの問題のためのマーカーレスAR可視化システムの構築と適用性の検討，土木学会論文集F3（土木情報学），79巻，2号，I.192-I.199，2016.

スマートグラス XREAL を用いた土木構造物の MR 可視化システムの構築

Development of a MR visualization system using hybrid method of marker-based and location-based

都市環境学科 4 年 船江 倅郁
Sachifumi Funae

1. はじめに

著者らはこれまで、ロケーションベース手法を用いた水中構造物の可視化システム構築¹⁾を行ってきた。しかし、使用デバイスが頭部着装型であったため、ヘルメットの着装に難があり、現場における使用性と安全性に課題があった。

そこで、本研究では眼鏡型スマートグラスを採用したシステムを構築するとともに、6 自由度トラッキングによる空間固定表示とハンドトラッキング操作の導入により現地運用における使用性と安全性の向上を目指す。本報告では、本システムを実際の構造物へ適用し、有用性の検討を行った。

2. XR 可視化システム

本システムのフローチャートを 図-1 に示す。

(1) 開発環境, 操作機能

(a) 開発環境

本研究では、統合開発環境として Unity を使用し、開発ツールキットとして UnitySDK を使用した。Unity は安定性を考慮し、LTS の最新バージョンへ適宜更新する。使用機器構成を 図-2 に示す。可視化デバイスには、XREAL 社製の眼鏡型スマートグラスである XREAL Air 2 Ultra, 端末には同社製の Beam Pro を使用した。本機は軽量で眼鏡型のため身体的制約が小さく、現場において設計図面や CAD モデルを実空間へ表示できる。また、6 自由度トラッキングに対応し、使用者の位置および回転変化を反映した重量が可能である。土木現場ではヘルメット着用が義務付けられているため、ヘルメット着用時でも併用可能な眼鏡型デバイスは現場適用性が高い。以上より、本機を採用した。

(b) ハンドトラッキング機能

ハンドトラッキングとは、デバイスに搭載されたセンサ情報を用いてユーザーの手の位置や姿勢、指の状態を、入力として利用する機能である。本研究では、UnitySDK に搭載されているハンドトラッキングを使用し、手指の検出結果を用いて「掴む」「移動」「回転」といった操作を実現する。ハンドトラッキングは、まずシステムが手の形状を認識し、手の三次元位置および姿勢を継続的に更新することで成立する。この時、手がモデルの当たり判定（コライダー）領域に侵入した状態で掴み（つまむ）動作を検出すると、モデルが「選択された」と判断され、手の動きに従ってモデルの位置と回転が更新される。さらに、掴みを解除すると追従更新は停止し、モデルは所定の挙動に移行する。

(2) プリプロセス

Unity 内で可視化情報、位置情報の入力並びにユーザーインターフェース（以後、UI）の設定を行う。UI の設定は、ハンドトラッキング機能や、ボタン操作の設定を行う。




図-1 フローチャート




図-2 使用機器構成

(a) 可視化モデル設定

CAD モデルを fbx 形式に変換し、Unity 内に取り込む。

(b) 表示設定

事前に Unity 内で可視化モデルの初期配置位置や UI の初期位置配置、カメラの描写距離等の設定を行う。可視化モデルの初期配置位置は、アプリ起動時のモデルの位置および角度を設定する。

(3) メインプロセス

(a) 接触判定の自動生成

対象の可視化モデルを、ハンドトラッキングにより操作可能とするため、可視化モデル全体に対して接触判定の自動生成を行う。具体的には、可視化モデルの外形（メッシュ形状）に基づき接触判定（コライダー）を自動生成・調整することで、可視化モデルに対して確実に選択・掴みとして認識される。操作中は手の動きに従って可視化モデルが移動・回転するよう追従方式を設定し、非操作時には速度成分をゼロにすることで、可視化モデルの意図しない移動や落下を防止し、その場に保持される挙動とする。

(4) ポストプロセス

(a) ハンドトラッキングによる手動補正

ハンドトラッキング機能を用いて可視化モデルを直接選択し、移動操作によって大まかな手動補正を行う。




図-3 適用場所




図-4 可視化モデル

(b) UI ボタンによる手動補正

ハンドトラッキングではミリ単位の精密な位置合わせが困難なため、UI ボタンによる微小調整機能を実装した。UI ボタン操作によって段階的に補正し、重畳精度の向上を図る。移動は 10 cm 毎、回転は 1° 毎とし、空間座標系 x, y, z の 3 軸に対して正負方向の操作を可能とする。空間座標系の詳細については、文献²⁾を参照されたい。

(c) ハンドトラッキング手動補正 ON/OFF システム

現地運用で長時間可視化する際に、ハンドトラッキングの誤作動が想定される。よって、モデルの表示状態を維持したまま、ハンドトラッキング手動補正を無効化する ON / OFF 機能を搭載した UI ボタンを採用する。手動補正の完了後は UI ボタンを OFF にし、誤作動を防止する。

3. 適用

(1) 適用場所

本システムの有用性検討のため、図-3³⁾に示す東京都大田区羽田旭町に位置する青宙橋で適用を行った。アプリ起動時の視点は、整備場駅側橋端から約 30m の位置に設定し、可視化方向は矢印に示す向きとする。

(2) 適用モデル

可視化モデルを図-4に示す。可視化モデルは橋長 86 m、幅員 4 m の青宙橋である。元データは地形等を含んでいたため容量が大きく、操作時の負荷が課題であった。本報告では可視化に必要な図-4に示す橋梁部のみのモデルを用いた。また、可視化中に 1 倍、1/20 倍、1/100 倍を選択可



図-5 現地可視化結果

能なスケール変更 UI を実装した。これより、縮尺表示による全体像の俯瞰や共有等の多様な用途への展開が可能となった。

(3) 可視化結果

可視化結果を図-5に示す。スマートグラスの使用により重畳中も現実空間の視認性が確保され、現地運用における安全性を配慮した可視化が可能であることを確認した。また、ヘルメット着用が求められる土木現場を想定しても、可視化が実施可能であり、本システムの現場適用性を示した。

ハンドトラッキングによる手動補正と UI ボタンによる微調整機能を併用することで、重畳作業の効率化と高精度化が図れることを確認した。また、ハンドトラッキング手動補正の ON / OFF 機能の実装により、長時間の可視化の際に起きる誤作動を抑制できることも確認できた。

4. おわりに

本論文では、スマートグラスを用いた土木構造物の可視化システムの構築を行うとともに、本システムを実際の構造物へ適用し、以下の結論を得た

- スマートグラスを用いる本システムはヘルメットの装着が可能であり、実際の現場において安全に重畳でき、その有用性を確認した。
- ハンドトラッキングと UI ボタン操作機能を併用することで、本システムの現場での高精度かつ実用性を確認した。

今後は、条件が異なる現場への適用と更なる可視化表現の検討を行っていく予定である。

参考文献

- 1) 中祖諒大, 樫山和男, 大原幸大, 琴浦毅: ロケーションベースとマーカーベース手法を用いたハイブリッド MR 可視化システムの構築, 土木学会論文集, 81 巻, 22 号, 24-22008, 2025
- 2) 鈴木雅大, 大川博史, 中祖諒大, 樫山和男: 小型 GNSS 受信機を用いた水域環境における AR 可視化システムの構築, 土木学会論文集, 79 巻, 22 号, 22-22013, 2023
- 3) 国土地理院: 地理院地図, < <https://maps.gsi.go.jp/> >, (入手 2026.1.6) .

有限要素法に基づく遮音壁の吸音効果を考慮した音場解析

Sound Field Analysis Considering the Sound Absorption Effect of Noise Barriers Based on the Finite Element Method

都市環境学科 4 年 三矢 諒音
Ryouto MITSUYA

1. はじめに

既往の研究¹⁾では、波動音響理論に基づき、有限要素法を用いた音場解析手法が行われてきた。しかし、多孔質吸音材内の構造特性を直接考慮した解析は十分に行われていない。本研究では、現実的な問題への適用として、計算規模の大きい遮音壁周辺の音場を対象とした 3 次元球面波解析を行い、遮音壁の吸音効果について比較した。

2. 数値解析手法

2.1 支配方程式

均一媒質中の波動伝播を表す支配方程式は、以下に示す 3 次元非定常波動方程式である。

$$\frac{\partial^2 p}{\partial t^2} - c^2 \frac{\partial^2 p}{\partial x_i^2} = 0 \quad \text{in } D \quad (1)$$

ここで、 p は音圧、 c は音速、 t は時間、 x_i は 3 次元空間の座標、 D は解析領域を表す。

本研究では、開境界処理として PML 法を使用するため、減衰項を含む修正波動方程式として式 (2) を、 p の時間積分項において畳み込み積分を適用するための補助変数 Φ_i を求める移流方程式として式 (3) を用いる。加えて、多孔質材料内の空気伝搬音特性を予測する Zwicker-Kosten 方程式²⁾は式 (4) となる。

$$\frac{\partial^2 p}{\partial t^2} + \alpha \frac{\partial p}{\partial t} + \beta p - c^2 \frac{\partial^2 p}{\partial x_i^2} - c^2 \frac{\partial \Phi_i}{\partial x_i} = 0 \quad \text{in } D, D_{\text{PML}} \quad (2)$$

$$\frac{\partial \Phi_i}{\partial t} + \mathbf{A} \Phi_i + \mathbf{B} \frac{\partial p}{\partial x_i} = 0 \quad \text{in } D_{\text{PML}} \quad (3)$$

$$\frac{\partial^2 p}{\partial t^2} + \frac{\sigma \phi}{\rho k_s} \frac{\partial p}{\partial t} - \frac{c^2}{k_s} \frac{\partial^2 p}{\partial x_i^2} = 0 \quad \text{in } D_{\text{por}} \quad (4)$$

ここで、 σ は流れ抵抗、 ϕ は多孔度、 k_s は構造定数、 ρ は密度、 D_{PML} は PML 領域、 D_{por} は吸音材領域を表す。 $\sigma_x, \sigma_y, \sigma_z$ は各方向の減衰パラメータであり、減衰パラメータは PML 領域では非 0、解析領域では 0 となり音波を吸収する役割を持つ。

2.2 境界条件

境界条件は以下のように表される。

$$p = \hat{p} \quad \text{on } \partial D_p \quad (5)$$

$$q_n = -\frac{\partial p}{\partial n} = \hat{q}_n \quad \text{on } \partial D_q \quad (6)$$




図-1 大規模解析モデル

ここで、 $\hat{p}$ は既知の音圧、 n は解析境界からの外向き法線ベクトルである。また、 ∂D_p は Dirichlet 境界条件、 ∂D_q は Neumann 境界条件が考慮される境界である。

2.3 離散化手法

式 (2)~(4) に対して Galerkin 法に基づく重み付き残差法を適用し、Green-Gauss の定理を用いて空間離散化を行う。空間方向の離散化には四面体一次要素を用いた有限要素法により離散化を行い、時間方向の離散化には差分法を用い、陽解法により求める。

3. 数値解析例

3.1 解析条件

図-1 に解析モデルを示す。x, y 方向の両端、z 方向の上端に PML 層を設ける。遮音壁位置から x 方向に -5.0 [m]、z 方向に $+1.0$ [m] の地点に仮想音源、z 方向に -1.0 [m] の地点に仮想鏡像音源を設ける。微小時間増分量は 6.67×10^{-6} [s]、要素分割幅は 2.5×10^{-2} [m] とし、PML 層を 1.1 [m] とする。壁の種類としては、完全反射の剛壁、多孔質部材料であるグラスウールの壁を想定する。入射波は、Lubich の擬似インパルスを用いる。また、本解析の計算には京都大学学術情報センターのスーパーコンピュータシステム (Camphor3) を用いた。

3.2 解析結果

図-2 に、 $t=0.0124$ [s] における xz 平面中心断面の音圧分布を示す。黄色枠の拡大部より、剛壁では壁面直前に高い音圧帯が形成されていることが確認できる。一方、多孔質部材では同位置の高音圧帯が小さく、壁内部




図-2 可視化結果 ($t = 0.0124[s]$)




図-3 可視化結果 ($t = 0.0181[s]$)

へ音圧分布が現れている。これは音波が材料内へ侵入し、内部損失によって音響エネルギーが吸収されるためである。また、多孔質部材では壁背後側に到達する音圧も相対的に低く、吸音効果による減衰が視覚的に確認できる。図-3に $t=0.0181[s]$ における音圧分布を示す。①領域において、壁は反射が強く波面が明瞭であるのに対し、多孔質部材は吸収により反射が抑制され、波面が不明瞭となる。②領域においては、剛壁は回折により背後側にも波が回り込み波面が明瞭であるのに対し、多孔質部材は背後側の波面が弱く低音圧域が広がり、到達音が低減している。

図-4、図-5に各受音点における音圧の時刻歴波形を示す。受音点1では、壁到達以前の入射波形は両条件で一致しており、解析条件および数値計算の妥当性が確認できる。その後、剛壁では強い反射波が形成されるのに対し、多孔質部材では反射波の振幅が抑制された。これは、多孔質材料の内部損失により音響エネルギーが吸収されるためであり、位相変化も確認された。受音点2では、音圧の立ち上がりが現れ、その後、剛壁では回折波により一定の音圧が観測されるのに対し、多孔質部材では振幅が低減し、透過音の減衰が確認された。以上より、多孔質部材の導入により遮音壁通過後の音圧が低減し、遮音性能が向上することが示された。

4. おわりに

本研究では、多孔質吸音材を解析モデルに組み込むとともに、遮音壁周辺の音場を対象とした3次元球面波解析を行い、完全反射を仮定した剛壁の場合との比較により、提案手法の妥当性について検討を行った。その結果、以下の結論を得た。




図-4 受音点1における音圧の時刻歴波形




図-5 受音点2における音圧の時刻歴波形

- 可視化結果から、多孔質部材においては音波の透過および音圧分布の低減が確認され、剛壁と比較して吸音によるエネルギー減衰が生じていることを視覚的に示した。
- 各受音点における時刻歴波形の比較から、多孔質部材では反射波および透過波の振幅が抑制され、遮音壁による減衰効果が確認された。

今後の課題としては、AMR法の導入、実音源との畳み込み、振動に起因する音を扱うための振動方程式の導入、ならびにNURBS-Enhanced FEM (NEFEM)を用いた曲面遮音壁周辺の波動伝播解析を実施し、より現実に即した問題への適用を図る予定である。

参考文献

- 1) 深澤一志, 宮内暖季, 樫山和男, 吉川仁: 有限要素法による音場解析手法の構築とその可聴化, 土木学会論文集, 土木学会, Vol.80, No.15, 23-15021, 2024.
- 2) C. Zwicker and C. W. Kosten: Sound Absorbing Materials, Elsevier Science Ltd, pp.18-24, 1949.
- 3) 村瀬正典, 川真田智, 栗木稔, 丸山暉彦: 多孔質舗装上での音波の伝搬に関する研究, 舗装工学論文集, 土木学会, Vol.4, pp.41-46, 1999.

VR 技術を用いた HMD 型浮上式高速鉄道騒音評価システムの構築

Development of a VR-based HMD System for Evaluating Floating High-Speed Railway Noise

都市環境学科 4 年 増田 樹
Tatsuki Masuda

1. はじめに

著者らはこれまで、没入型 VR 装置に基づく高速鉄道の騒音評価システムの構築¹⁾を、幾何音響理論に基づくリアルタイムシミュレーション手法を用いて行ってきた。しかし、従来システムは巨大な没入型装置を用いていたため、計画地点での使用は困難であり、住民へ合意形成の手段として用いることはできなかった。また、屋外の騒音評価に着目しており、屋内での騒音評価を行うことができなかった。

そこで本研究では、可搬性にすぐれる HMD に基づくシステムを構築するとともに、適用性の向上を目的として、屋内での騒音評価機能の実装を行った。

2. 浮上式高速鉄道騒音評価システム

2.1 システム概要

本システムのフローチャートを図-1 に示す。入力データとして車両走行条件、音源の音響パワーレベル、構造物や軌道の形状を設定する。時間ループ内で音源位置と観測者位置を取得し、幾何音響理論に基づき騒音レベルが計算される。デバイスには、Meta Quest 3 を用いる。統合開発環境として、ゲームエンジンの Unity を用いてシステム構築を行う。アプリケーション作成のための開発キットに、XRToolkit を使用する。

3. 音響計算手法

3.1 幾何音響理論を用いた音響計算

本研究では、日本音響学会道路交通騒音調査研究委員会の ASJ RTN-Model 2023²⁾を用いて音響計算を行う。これは幾何音響理論に基づき、音源を半自由空間の点音源として扱うモデルである。ASJ モデルにおいて、受音点での音圧レベル L_p (dB) から音源の音圧レベル L_W (dB) を算出する式は以下の通りである。なお、本研究では車両は橋梁の上を走行するため、半球状の点音源を仮定している。

$$L_W = L_p + 20\log_{10}r + 8 - \Delta L_{cor} \quad (1)$$

ここで、 r は音源から受音点の距離、 ΔL_{cor} (dB) は回折や指向性による減衰の補正量である。また、 L_p は受音点での音源からの伝搬音の圧力レベルの合成値 (dB) であり、次式で表される。

$$L_p = 10\log_{10} \sum_{k=1}^i (10^{L_{pi}/10}) \quad (2)$$

ここで、 i は合成する音源の数である。




図-1 本システムの構成




図-2 指向性モデルに用いる角度の定義

3.2 指向性による補正

鉄道の走行音は走行ライン及び上方には音が伝播しづらく、側面方向に伝播しやすい双指向性の特徴を持つ。本研究では、走行音を指向性を有する点音源として扱い、以下に示す指向性モデルを適用する。

$$L_{dir} = 10\log_{10}(\cos^n \theta (0.1 + 0.9 \cos \varphi)) \quad (3)$$

ここで、 θ は図-2 に示すように、観測者から見た走行ラインへの最短地点を基点とした音源への角度、 φ は音源から見た観測点への仰角であり、 θ 及び φ の値は車両と観測点の位置座標から算出をしている。また、 n は指向性係数であり値が大きいほど前後方向と鉛直方向には広がりにくく、側面方向に広がりがやすい。

3.3 構造物音の考慮

走行時には空気圧変動による空力音と、車両が高架道路上を走行する際の構造物振動による構造物音が車外騒音に影響を与える。本研究では、図-3 に示すように、構造物音を車両走行により発生する空力音に連動して移動する無指向性の仮想点音源として扱う。構造物音の音響

VR 技術を用いた超音速機騒音評価システムの実用性の向上

*Studies on Quality Improvement of Supersonic Aircraft Noise
Evaluation System Using Virtual Reality Technology*

都市環境学科 4 年 太田 絢乃
Ayano OTA

1. はじめに

著者の研究室では基地周辺の騒音対策を行うために、幾何音響理論を用いた超音速機の騒音評価システムの構築¹⁾を行ってきた。本研究では、システムの適用性の向上を目的として、屋外のみならず屋内の騒音評価を可能とするとともに、離陸方向の変更および 2 機同時および連測離陸が可能なシステムを構築した。

2. 音響計算手法

本報告では、日本音響学会の ASJ RTN-Model 2023 を用いて音響計算を行う。これは音源を自由空間における点音源として扱うモデルであり、幾何学的な反射のみで音の伝播を記述する幾何音響理論に基づいた伝播計算を行う。

2.1 屋外における伝播計算

本報告で用いる VR システムは、観測者の位置といった条件をリアルタイムに変更可能とし、非定常に変化する騒音レベルの算出および可聴化を行う。音源から $SD(m)$ 離れた球面上における音圧レベル $L_p(dB)$ は音源の音響パワーレベル $L_W(dB)$ をもとに次式から算出することができる。

$$L_P = L_W - 20\log_{10}SD - 11 + \Delta L_{cor} \quad (1)$$

ここで、 ΔL_{cor} は回折や地表面効果等による減衰に関する補正項である。本報告では補正項として指向性のみを考慮しており、90 度ダイポールモデルを適用している。

2.2 屋内における伝播計算

屋内観測点における騒音レベル (SPL) は屋外における評価式を基に補正を加えた次式、屋内騒音レベル評価式より算出した。

$$SPL = L_P - TL + 10\log \frac{S_{sum}}{A} + 3 \quad (2)$$

ここで、 L_P は建物がない場合の騒音レベル (dB)、 TL は透過損失 (dB)、 A は材料の吸音率にその面積を乗じた全吸音力 (m^2)、 S_{sum} は透過する面の総面積 (m^2) である。

3. 超音速機騒音評価システム

本研究では、没入型 VR 装置 Holostage を用い、利用者位置と飛行条件に基づく映像・音響をリアルタイム生成する。音響には Max と Ambisonics を用い、OSC で




図-1 本システムの構成




図-2 建物モデル及び寸法

映像と同期させることで、位置に応じた騒音体感を実現した(図1)。

4. 屋内騒音シミュレーションシステム

本報告では、基地近隣地域の住宅を想定し、屋内への騒音伝搬シミュレーションを適用している。そのシミュレーション条件および構成について以下に示す。

4.1 音源および建物モデルの条件

音源データには F-2(エンジン位置) を用い、初速 0km/h から離陸時 244km/h へ加速後、等速飛行へ移行する設定とした。屋内シミュレーションの対象となる建物モデルは、図2に示す幅 3.6m、奥行き 3.6m、高さ 2.4m の直方体とし、壁面の材質はコンクリート(透過損失:53.5dB)とした。騒音レベルの算出には式(2)を用いる。その際、音の透過面は側方 4 面と天井の計 5 面とし、全吸音力は各材料の吸音率にその面積を乗じて算出した。また、窓ガラスの条件については、以下の 2 種類を設定した。

- 一重窓：面積 1.746m²，厚さ 3mm，透過損失 25dB
- 二重窓：面積 1.746m²，厚さ 3mm および 6mm のガラスと 50mm の空気層により構成（総厚 59mm），透過損失 33dB

5. 離陸方向の変更および 2 機離陸システム

本報告では，風向きによる滑走路運用の変更に対応するため，離陸方向の変更を再現可能な機能を実装した。加えて，スクランブル発進などの複数機運用への対応を見据え，システムを 2 機離陸が可能な構成へと拡張した。本章では，構築したシステムにおいて，離陸方向変更時の騒音伝搬の整合性，2 機同時離陸時における音圧レベル変化の物理的な整合性，さらに実測値との比較による 2 機連続離陸システムの妥当性について検証を行う。

5.1 測定環境および計算手法

音源の音響パワーレベルは 150dB，受音点は音源から水平に 200m の位置で高さは地上 1.5m とした。音源・建物モデルの条件は前述の通りである。また，2 機離陸システムにおける音圧レベルの合成は次式を用いる。

$$L_{\text{sum}} = 10 \log_{10} \left(10^{\frac{L_1}{10}} + 10^{\frac{L_2}{10}} \right) \quad (3)$$

ここで， L_1 ， L_2 は 1 機目，2 機目の音圧レベルである。検証として，1) 離陸方向変更時の ASJ モデル計算値との比較（屋外・屋内窓なし・一重窓・二重窓），2) 単機と 2 機同時離陸時の音圧レベル比較（屋外のみ）を行った。さらに 2 機連続離陸については，茨城空港での測定と同様の観測地点にて VR 空間上でシミュレーションを実施した。

5.2 解析結果

離陸方向変更の結果を図 3 に，単機および 2 機同時離陸の比較を図 4 に，2 機連続離陸システムにおける計算値と実測値の比較を図 5 に示す。なお，最大音圧レベルを基準に校正を行った。結果として，離陸方向変更時の計算値の傾向が一致すること，および建物部材に応じた減衰が得られたことから屋内シミュレーションの整合性を確認した。また，2 機同時離陸時の音圧上昇も確認され，物理的な整合性が示された。2 機連続離陸システムについても，計算値のピークおよび変動傾向が実測値と概ね一致し，システムの妥当性を確認した。一方で，機体通過前の音圧上昇部において実測値との若干の乖離がみられた。これは現在のシステムにおける音源の指向性の考慮不足が原因であると考えられるため，今後の課題として指向性モデルの改善を検討する。

6. おわりに

本報告では，騒音評価システムの実用性の向上のため，屋内での騒音評価を可能とするとともに，超音速機の離陸方向の変更機能及び複数機の離陸機能を実装した。そこで以下の結論を得た。




図-3 離陸方向変更機能の整合性検証結果




図-4 2 機同時離陸システムの整合性検証結果




図-5 2 機連続離陸システムの妥当性検証結果

- 屋内での騒音評価を可能にし，建材による音の減衰効果を確認した。
- 離陸方向の変更機能および複数機の同時および連続離陸機能を実装し，その整合性および妥当性を確認した。

今後は実測値との乖離を解消するための指向性モデルの検討を行っていく予定である。

参考文献

- 1) 梅谷三咲，樫山和男：VR 技術を用いた超音速機騒音評価システムの品質向上，第 52 回土木学会関東支部技術研究発表会講演概要集，2024。

ベイズ最適化を用いたリアルタイム浸水域予測モデルの高精度化の検討

Improving Real-time Inundation Prediction via Bayesian Optimization

都市環境学科 4 年 長濱 悠太郎
NAGAHAMA Yutaro

1. はじめに

近年、気候変動の進展に伴って大型台風やゲリラ豪雨の発生頻度が増加し、河川氾濫のリスク増大が懸念されている。洪水による被害を低減するには、降雨や流量の情報を迅速に整理し、情報発信を行うことが有用である。

中山ら¹⁾は、特異値分解をはじめとした次元圧縮手法と、深層学習を適用した浸水域予測を行っているが、モデルに対するハイパーパラメータの最適化が行われていなかった。そこで、本研究ではベイズ最適化を用いてハイパーパラメータの最適化を行い、予測精度の向上について検証を行った。

2. 解析手法

2.1 モデル構築と解析の手順

本研究におけるフローチャートを図-1 に示す。(a) の学習段階では、以下の手順でモデルの構築を行った。

1. 越流水深を変化させ、物理シミュレーションによる浸水解析を実行し、多様な氾濫ケースを作成する。
2. シミュレーション結果から各格子点の浸水深を抽出し、仮想浸水分布とする。
3. 仮想浸水分布に対し次元圧縮を適用し、学習における目的変数となる係数行列を得る。
4. 機械学習を用いて、越流水深の時系列データから係数行列を推定するモデルを構築する。

(a) での学習を経て構築したモデルを使用して、(b) の推論段階では以下の手順で推論を行った。

1. 構築したモデルに 1~12 時間の越流水深を与え、係数行列を予測する。
2. 出力された係数行列を用いて元の浸水分布を復元し、精度の評価を行う。

2.2 浸水解析モデル

氾濫解析には、氾濫水の挙動を精密に再現可能な Dynamic Wave 法を適用した。本手法は、以下の x 、 y 方向の運動量保存則と質量保存則により構成される。

$$\frac{\partial M}{\partial t} + \frac{\partial(uM)}{\partial x} + \frac{\partial(vM)}{\partial y} + gh \frac{\partial H}{\partial x} = -gh \frac{n^2 u \sqrt{u^2 + v^2}}{R^{\frac{4}{3}}} \quad (1)$$

$$\frac{\partial N}{\partial t} + \frac{\partial(uN)}{\partial x} + \frac{\partial(vN)}{\partial y} + gh \frac{\partial H}{\partial y} = -gh \frac{n^2 v \sqrt{u^2 + v^2}}{R^{\frac{4}{3}}} \quad (2)$$

$$\frac{\partial h}{\partial t} + \frac{\partial M}{\partial x} + \frac{\partial N}{\partial y} = 0 \quad (3)$$

ここで、 u は x 方向の流速、 v は y 方向の流速、 h は水




図-1 浸水域予測モデルの構築・浸水域の推定




図-2 対象地域とその標高

深、 H は基準面からの水位、 R は径深、 $M = uh$ は x 方向の単位幅流量、 $N = vh$ は y 方向の単位幅流量、 g は重力加速度、 n はマンニングの粗度係数である。なお、空間方向の離散化には差分法、時間方向の離散化には陽解法を使用し、タイムステップは $0.2[s]$ 、粗度係数は基盤地図情報の土地利用分類²⁾に基づいて設定している。

2.3 学習データ

本研究では、前項の浸水解析モデルによって得られる浸水深を学習データとした。解析領域には図-2 に示す、東京都荒川区、台東区を中心とした荒川右岸域を設定し




図-3 作成した仮想越流水深の一例




図-4 氾濫シュミレーションによる解析結果

た．図の左上に示される1点での越流を仮定し，解析を実行した．学習データの作成に当たって，越流水深の1時間ごとの時系列データを，下記の式を用いて作成し，浸水解析モデルに入力した．

$$h = \left\{ \sin \left(a - 0.5 + \frac{t}{720} \pi \right) + 0.3b \right\} \times 2c \quad (4)$$

ここで， a, b, c は 0~1 の乱数， t は 60 分ごとの時刻であり，上記の式を用いて 1,000 ケースの仮想越流水深を作成した．なお作成したデータに $h < 0$ が含まれる場合には，ケースを破棄して再作成を行う．仮想越流水深の一例を図-3 に，浸水域を図-4 しめす．本研究では，1~12 時間の越流水深を，深層学習における説明変数とする．

3. 次元圧縮手法および予測手法

3.1 次元圧縮手法

次元圧縮は，情報の損失を許容した上で，高次元データを低次元に縮約する手法である．入力データを低次元化することで，計算と学習の効率化が見込める．本研究では，221,392 次元の元データを 1~20 次元に圧縮して実行した．次元圧縮手法には特異値分解 (Singular Value Decomposition 以下:SVD)³⁾を用いた．SVD は，行列を複数の特異ベクトルと，対応する特異値に分解する手法である． $m \times n$ の行列 A は以下のように分解される．

$$A = U \Sigma V^T \quad (5)$$

ここで U は $m \times r$ の左特異ベクトル (係数行列)， Σ は $r \times r$ の対角行列 (特異値)， V^T は $r \times n$ の左特異ベクトル (特徴量) である．また， r は圧縮次元数である．本研究では，SVD によって得られた係数行列 U を，

表-1 次元圧縮の実行条件

対象データ	12 時間後の 1000case の氾濫域
入力次元数	221,392 次元 (404×548)
次元圧縮手法	特異値分解 (SVD)
圧縮次元数	1~20 次元
評価手法	RMSE

表-2 深層学習モデルの学習条件

訓練データ	800case
テストデータ	200case
説明変数	越流水深
目的変数	係数行列
学習回数	最大 500 回
各種パラメータ	最低損失を 10 回連続で更新しない場合早期終了
損失関数	平均二乗誤差
検証方法	交差分割

深層学習における目的変数とする．実行条件は，表-1 に示す．

3.2 深層学習モデル

本研究では，深層学習手法として Deep Neural Network (以下:DNN) を使用した．DNN はニューラルネットワークを用いて，複雑なパターンや特徴を学習する代表的な機械学習のモデルである．説明変数に 1 時間ごとの越流水深，目的変数に係数行列をとる学習モデルを作成する．なお学習の効率化のため説明変数，目的変数の標準化を行っている．実行条件は表-2 の通りである．

3.3 時系列学習モデル

本研究では，越流水深のような時系列データの動的特徴をより適切に捉えるため，Recurrent Neural Network (以下:RNN)，Long Short-Term Memory (以下:LSTM)⁴⁾，Gated Recurrent Unit (以下:GRU)⁵⁾を使用した．これらのモデルはいずれも時系列データから特徴を抽出する能力が高く，越流水深の時間的変化と浸水域の関係性を効率的に学習することが期待できる．

3.3.1 RNN

RNN は，過去の情報を保持しながら学習を進めることができ，時間的依存関係を学習できるモデルである．ただし比較的単純な構造のため，長期的な依存関係には限界がある．

3.3.2 LSTM・GRU

LSTM は RNN の改良モデルであり，入力ゲート，忘却ゲート，出力ゲートの 3 つのゲートを導入したことで，RNN の長期的依存関係が苦手であった点を克服している．GRU は LSTM を簡略化したモデルであり，リセットゲートと更新ゲートの 2 つを持つ．RNN や LSTM と比較して予測時間の短縮が期待できる．

表-3 ハイパーパラメータの探索範囲と最適化結果

	探索条件	DNN Opt.	DNN Prev.	探索条件	RNN Opt.	LSTM Opt.	GRU Opt.	RNNs Prev.
中間層数	2~6 層 (32~512)	2 層 (86-86)	4 層 (128-64 -32-16)	1~3 層 (32~256)	3 層 (101-141 -188)	1 層 (208)	1 層 (124)	1 層 (64)
バッチサイズ	8, 16, 32, 64, 128	32	32	16, 32, 64, 128	32	64	64	32
活性化関数	relu, elu, tanh, swish	tanh	relu	-	-	-	-	-
学習率	1e-5~1e-2	0.000546	0.001000	1e-5~1e-2	0.000087	0.000483	0.000157	0.001000
ドロップアウト率	0.01~0.2	0.000580	なし	0.0~0.5	0.000768	0.000652	0.000157	なし




図-5 圧縮次元数と RMSE の関係




図-6 浸水域予測に要する時間

3.4 評価手法

次元圧縮を用いた浸水域の復元に関する評価指標には、以下に示す二乗平均平方根誤差 (Root Mean Square Error 以下:RMSE) および差異を用いた。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - f_i)^2} \quad (6)$$

$$\text{Difference} = x_i - f_i \quad (7)$$

ここで n はデータ数, x_i は復元された浸水深, f_i はシュミレーションによる浸水深である。

4. 学習モデルの最適化手法

学習モデルの最適化にはベイズ最適化を用いた。ベイズ最適化は、未知の目的関数を確率モデルで近似し、獲得関数に基づいて次の点を探る手法である。本研究ではベイズ最適化の実行のため Python 上の最適化ライブラリ Optuna⁶⁾ を使用している。試行回数は 500 回の予備実験を行った結果 150 回程度で収束したため、余裕をとって 300 回としている。乱数条件により結果が異なるため、10,15,20 次元に最適化を行い、最も高精度に復元できたモデルのパラメータを代表値とした。パラメータの探索条件は表-3 のとおりである。

5. 開発環境

本研究の開発環境は以下のとおりである。ハードウェアは、CPU: Intel Core i7-14700F, RAM: 32GB. GPU: NVIDIA RTX 4070Ti SUPER, VRAM: 16GB を使用した。ソフトウェアは、Windows 内に仮想の Linux 環境を構築した。実行環境に Anaconda 3, Python 3.12.3 を使用し、ライブラリとして、TensorFlow 2.20.0, Scikit-learn 1.7.2, Optuna 4.5.0 を使用している。

6. 実行結果

6.1 最適化の実行結果

最適化したパラメータの結果を表-3 に示す。表中の最適化モデル (Opt.) は本研究で最適化したモデルであり、既存のモデル (Prev.) は中山らの研究報告に基づき設定したモデルである。なお RNN 系列の既存モデルは同条件でユニットをそれぞれのモデルに置き換えて実行している。モデルの最適化は 1 ケースあたり 15 時間程度で実行可能であり、従前の経験則に基づく場当たり的なチューニングと比較すると、大幅な効率化を達成することができた。

6.2 復元精度について

前項の最適化パラメータを適用したモデルを用いて浸水域予測を行い、復元した氾濫域を 1,000 ケースの平均




図-7 各手法における浸水域予測と浸水差異の可視化結果（15 次元）

RMSE を指標に評価を行った結果を図-5 に示す。実線は最適化モデル、破線は既存モデルを示している。最適化を行ったモデルでは、精度向上に差異はあるものの全てのモデルで既存のモデルよりも高い精度で復元を行うことができ、最も高精度に復元できたのは DNN モデルであった。また、浸水分布と浸水差異を図-7 に示す。いずれのモデルも越流水深の最大ケースでは危険側の予測をしていることが分かる。また可視化結果からも DNN モデルの復元精度が高いといえる。

6.3 予測時間について

浸水域の予測に要した時間（深層学習による係数行列の推論時間と、元の行列への復元時間の合計）を図-6 に示す。実線は最適化モデル、破線は既存モデルを示している。DNN モデルで 3 秒程度、RNN モデルで 9 秒程度、LSTM・GRU モデルで 2 秒程度の結果となった。推論時間は中間層数から大きく影響を受けることから DNN モデルでは短く、RNN モデルでは長くなったことが考えられる。中間層数に変わりのない LSTM モデル、GRU モデルでは既存モデルと同程度という結果になった。また LSTM モデルと GRU モデルの予測時間には、ほとんど差がなかった。以上より、予測時間の観点からは LSTM モデル、GRU モデルが優れているといえる。

7. おわりに

本研究ではベイズ最適化を用いて、リアルタイム浸水域モデルの高精度化を実行し、以下の結論を得た。

- ベイズ最適化によるチューニングの効率化と、最適化による精度向上を確認することができた。
- 最適化されたモデルは全て既存モデルより高精度

であり、特に DNN モデルが最も高い精度で復元できることを確認できた。

- 予測時間はモデルの層数に影響を受け、LSTM・GRU モデルが約 2 秒と最も高速であり、速報性の観点で優れていることが確認できた。
- 今後は、より高精度に復元可能な次元圧縮手法の検討および、多地点越流に対するモデルの適用について検証を行う。

参考文献

- 1) 中山 龍也, 山口 欽太, 一言 正之, 樫山 和男: 次元圧縮を適用した深層学習に基づくリアルタイム浸水域予測の高度化, AI・データサイエンス論文集, Vol. 6, No. 3, pp. 287-295, 2025.
- 2) 国土地理院, 国土基盤情報 <https://www.gsi.go.jp/kiban/> (参照 2025-09-17)
- 3) C. Eckart and G. Young: The approximation of one matrix by another of lower rank, *Psychometrika*, Vol. 1, No. 3, pp. 211-218, 1936.
- 4) S. Hochreiter and J. Schmidhuber: Long Short-Term Memory, *Neural Computation*, Vol. 9, No. 8, pp. 1735-1780, 1997.
- 5) K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk and Y. Bengio: Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, *Proc. of EMNLP 2014*, pp. 1724-1734, 2014.
- 6) Akiba, T., Sano, S., Yanase, T., Ohta, T., and Koyama, M.: Optuna: A Next-generation Hyperparameter Optimization Framework, *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19)*, pp. 2623-2631, 2019.

深層学習を用いた山向き小崖の自動抽出における損失関数の最適化

Optimization of Loss Function Parameters for Automatic Extraction of Deep-seated Gravitational Slope Deformation Using Deep Learning

都市環境学科 4 年 藤ノ木 東周
Toushu Fujinoki

1. はじめに

日本列島の山地部において、大規模な山体崩壊の前兆現象として現れる「山体重力変形地形」の分布把握は、防災上極めて重要である。中でも「山向き小崖」は、斜面の最大傾斜方向とは逆向きに形成される線状の微地形であり、山体重力変形の代表的な変動地形として知られる。従来 これらの地形判読は航空レーザー測量データを用いた専門家による目視判読に依存していたが、広域を網羅するには多大な時間と労力を要する。

この課題を解決するために、近年深層学習による自動抽出が試みられている。しかし、山向き小崖は極めて微細な線状地形で占有面積が小さいため、深層学習のための教師データセットには著しいクラス間不均衡が生じる。吉田¹⁾の研究では、この問題への対策として Class-Balanced Focal Cross En-tropy Loss (以下 FCE)²⁾を採用し、クラス重み付けには Cui et al.³⁾が提案した「有効サンプル数」に基づく手法を用いていた。有効サンプル数に基づく重み付けは、データの重複を考慮した画期的な手法であり、画像分類タスクにおいてはその有効性が広く示されているが、画素単位の分類を行うセマンティックセグメンテーション、とりわけ極端なクラス間不均衡を伴う線状地形抽出タスクにおいて、同手法が最適であるかは十分に検証されていない。

そこで本研究では、FCE の重み補正強度を制御するパラメータ p を変化させた比較実験を行い、微細な線状地形抽出における最適なクラス重み設定について検証した。

2. 研究地域概要

越美山地は岐阜県南西部から福井県南東部にかけて広がる中起伏山地で、地域内には海拔 1,000 から 1,600m の山々が連なる。本研究では、同山地西部 (図-1 の範囲: 南北約 25km, 東西約 35km, 面積約 819 km²) を対象地域とした。Kaneda & Kono⁴⁾はこの地域全域を対象として、航空レーザー測量による 1m グリッド DEM から作成した赤色立体地図ステレオペアによる実体視地形判読を行い、本対象地域に総数 10,487 条 (山向き小崖: 6,480 条), 総延長約 716km におよぶ山体重力変形地形が存在することを示した (図-1)。





図-1 本研究地域の地形と山向き小崖分布



MPI赤色立体地図

正解ラベル

図-2 教師データ (MPI 赤色立体地図) と正解ラベル (山向き小崖分布) の例




図-3 セマンティックセグメンテーションのモデル

3. 研究手法

3.1 教師データ

教師データには、吉田の研究で最適とされた MPI 赤色立体地図²⁾ (2 m 解像度換算, 1024×1024 ピクセルの正方形タイル) を用いる (図-2)。正解画像は、山向き小崖のベクトルデータをラスター化し、幅 5 ピクセルに

拡張して用いた。テストデータは 15 タイルを用いた。

3.2 使用モデル

本研究では、画像の各画素に対してクラス分類を行うセマンティックセグメンテーションモデルを採用した。モデル構造には Oktay らによって提案された Attention 機構を備えた U-Net⁵⁾を用い、エンコーダー部分にはバックボーンとして EfficientNetV2S⁶⁾を採用した(図-3)。なお、エンコーダー部分では、ImageNet の事前学習済みの重みを初期値として用いる転移学習を導入している。入力データは地形表現図(画像)であり、出力として画素ごとのクラス予測確率マップを得る。

4. 損失関数とパラメータ設定

本研究では、損失関数として次に示す FCE Loss を使用する。

$$L_{\text{FCE}} = -\alpha_c(1-p_t)^\gamma \log(p_t) \quad (1)$$

ここで p_t はモデルの予測確率、 γ は易しいサンプルの寄与を抑制するフォールパラメータである。 α_c はクラス不均衡を補正するクラス毎の重み係数であり、本研究ではクラス 1 を「山向き小崖(前景)」, クラス 2 を「その他(背景)」と定義し、各クラスのデータセット内の総ピクセル数は $N_1=5,643,382$, $N_2=857,596,810$ である。また、クラス 1 の重み α_1 とクラス 2 の重み α_2 の重み比率を α_1/α_2 で定義する。

4.0.1 Cui et al. による重み付け

不均衡データにおける重み係数 α_c の設計において、Cui et al. はデータの重複を考慮した「有効サンプル数(Effective Number of Samples)」の概念を提唱した。有効サンプル数 E_n は、ハイパーパラメータ $\beta \in [0, 1)$ を用いて次式で定義される。

$$E_n = \frac{1 - \beta^n}{1 - \beta} \quad (2)$$

重み α_c は $1/E_n$ に比例するように設定される。吉田の研究では、この理論に基づき $\beta = 0.99$ を採用している。本タスクのピクセル数に適用した場合、前景と背景の重み比率は 78.29 となり、出現頻度の単純な逆数を用いる手法よりも補正強度が緩和される。

4.0.2 本研究における重み付け手法

有効サンプル数に基づく手法は画像分類において高い有効性が示されているが、線状地形の抽出を目的としたセマンティックセグメンテーションにおける最適性は十分に検証されていない。抽出対象が極めて微細な場合、理論値に基づく重み付けであっても前景が過剰に重視され、形状の肥大化を招く恐れがある。

そこで本研究では、出現頻度の逆数に基づく重みを基準とし、その補正強度をさらに柔軟に制御するため、強度制御用のべき乗パラメータ p を導入した次式を用いる。

$$w_c = \frac{1}{(N_c)^p + \epsilon} \quad (3)$$

$$\alpha_c = w_c \times \frac{C}{\sum_{i=1}^C w_i} \quad (4)$$

ここで N_c はクラス c の総ピクセル数、 C はクラス数 ($C = 2$)、 $\epsilon = 10^{-6}$ である。 $p = 1.0$ は単純な逆数重み(比率 151.97)に相当し、 $p < 1.0$ とすることで補正強度を抑制できる。各 p における重み比率の変化を図-4に示す。本実験では、先行研究との比較のため $\gamma = 2.0$ に固定し、 p を 0.0-1.4 の範囲で変化させて抽出精度を比較検証した。




図-4 パラメータ p とクラス間の重み比率

4.1 学習環境

学習条件と環境を表-1に示す。最適化手法には RAdam を用いた。これは、標準的な Adam が学習初期に不安定な挙動を示す課題を解決した手法である。学習率の分散を理論的に補正することで、本研究のような極端な不均衡データを含むタスクにおいても、初期段階から安定したパラメータ更新が可能となる。また学習率の調整には、ウォームアップとコサイン減衰を組み合わせたものを採用した。まず、学習開始直後の数エポックで学習率を低値から徐々に上昇させる「ウォームアップ」を行い、その後、学習率をコサインカーブに沿って滑らかに減少させる「コサイン減衰」を適用した。

表-1 学習条件と学習環境

学習条件	
項目	設定値
訓練データ数	2634 タイル
検証データ数	659 タイル
テストデータ数	15 タイル
クラス数	2
エポック数	100
バッチサイズ	10
損失関数	Class-balanced focal cross entropy
最適化手法	RAdam ⁸⁾
学習率調整	ウォームアップ付きコサイン減衰
評価関数	Macro Dice 係数
学習環境	
GPU	NVIDIA GeForce RTX PRO 4000
プログラム言語	Python 3.9.12
フレームワーク	TensorFlow 2.17

4.2 評価方法

モデルの山向き小崖の抽出精度を評価するため、本研究では DICE 係数を用いる。評価にあたっては、個々のテスト画像ごとに Dice 係数を算出して平均を取る手法ではなく、全テストデータタイルの全画素を合算して True Positive(TP), False Positive(FP), False Negative(FN) を集計し、Recall(再現率), Precision(適合率), Dice 係数を算出した。各指標の算出式は以下に示す通りである。これにより、山向き小崖が含まれないタイルや極端に少ないタイルによる評価値のばらつきを排除し、データセット全体に対するモデルの抽出性能をより適切に評価できる。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (5)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (6)$$

$$\text{Dice} = \frac{2\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (7)$$

5. 結果および考察

5.1 結果

p を 0.0 - 1.4 の範囲で 0.1 刻みで変化させて学習を行い、テストデータを推論した結果を表-2 に示す。また、Recall, Precision, Dice の変化を図-5 に示す。

本検討範囲では $p = 0.4$ において Dice 係数が 0.499 と最も高くなり、標準設定とされる単純逆数重み ($p = 1.0$, 重み比率 151.97) の 0.435 を上回る精度を示した。本タスクのような極端な不均衡データへの対策として、吉田¹⁾は有効サンプル数理論³⁾に基づく重み付け ($\beta = 0.99$) を採用している。この手法では、クラス間の重複を考慮することで重み比率を 78.29 まで緩和させているが、本研究の結果ではそれよりもさらに補正強度を抑制した $p = 0.4$ (重み比率 7.46) においてより良好な結果が得られた。

5.2 考察

この要因について、以下の二つの側面から考察する。第一に、本タスク特有の幾何学的特性である。山向き小崖は極めて微細な線状地形であり、わずかな領域の肥大化が偽陽性 (FP) の急増に直結する。吉田らの手法 (78.29) であっても、線状地形抽出という観点からは依然として前景クラスへの重みが過大であり、境界付近での過剰な抽出 (肥大化) を十分に抑制できていなかったと考えられる (図-7)。

第二に、セマンティックセグメンテーションにおける空間的相関の影響である。画素単位の分類では隣接画素間に強い相関があり、画素数比を機械的に打ち消す重み付けは「背景」という幾何学的な制約力を弱めてしまう。本結果は、既存の画像分類向け理論に基づく補正よりもさらに背景クラスの関与を強めることが、形状の忠

実度を維持するために有効であることを示唆している (図-6)。

表-2 パラメータ p の変化による Dice 係数の比較

p	重み比率 r	Dice
0.0	1.00	0.453
0.1	1.65	0.458
0.2	2.73	0.434
0.3	4.51	0.491
0.4	7.46	0.499
0.5	12.33	0.490
0.6	20.37	0.476
0.7	33.67	0.470
0.8	55.64	0.473
(従来手法)	78.29	0.436
0.9	91.95	0.450
1.0	151.97	0.435
1.1	251.14	0.388
1.2	415.04	0.371
1.3	685.91	0.367
1.4	1133.55	0.366




図-5 パラメータ p の変化による Dice 係数の比較




図-6 山向き小崖の境界

6. 結論

本研究では、FCE の重み補正強度を制御するパラメータ p を変化させた比較実験を行い、微細な線状地形抽出における最適なクラス重み設定について検証した結果、以下の結論を得た。




図-7 テストデータの推論結果

- 本タスクにおける最適な設定は $p = 0.4$ (重み比率 7.46) であり, 単純な逆数重みはもとより, 画像分類において有効性が示されている有効サンプル数理論に基づく補正よりも高い抽出精度を示した。
- 少数派クラス重みを強めるほど Recall は向上するが, 背景クラスの制約力が低下することで抽出線の肥大化を招き, Precision が著しく低下するトレードオフを確認した。

今後は, 解像度を 1m グリッドで作成した教師データによる学習の検討や, 学習モデルを他地域に適用し本研究の妥当性・汎用性の検証を行う。

謝辞

MPI 赤色立体地図の作成に用いられた航空レーザー測量データは, 国土交通省越美山系砂防事務所からご提供いただきました。

参考文献

- 1) 吉田美穂・金田平太郎, 2024, 深層学習を用いた山体重力変形地形抽出の試み-越美山地を対象として-, 中央大学理工学部都市環境学科卒業論文。
- 2) Lin, T., et al., 2017. Focal Loss for Dense Object Detection. arXiv.
- 3) Cui, Y., Jia, M., Lin, T., Song, Y., and Belongie, S., 2019, Class-Balanced Loss Based on Effective Number of Samples. arXiv, 1901, 05555.
- 4) Kaneda, H. and Kono, T., 2017, Discovery, Controls, and Hazards of Widespread Deep-Seated Gravitational Slope Deformation..., Journal of Geophysical Research Earth Surface, 122, 12, 2370-2391.
- 5) Oktay, O., et al., 2018. Attention u-net: Learning where to look for the pancreas. arXiv.
- 6) Tan, M. and Le, Q., 2021. Efficientnetv2: Smaller models and faster training. ICML.
- 7) Lin, T., Goyal, P., Girshick, R., He, K., and Dollár, P., 2017, Focal Loss for Dense Object Detection. arXiv, 1708, 02002.
- 8) Liu, L., Jiang, H., He, P., Chen, W., Liu, X., Gao, J., Han, J., 2020. On the variance of the adaptive learning rate and beyond. arXiv, 1908, 03265.

深層学習を用いた土地利用分類における 入力画像の空間的範囲が精度に与える影響の検討

Investigation into the Effect of Spatial Extent of Input Images
on Accuracy in Deep Learning-based Land Use Classification

都市環境学科 4 年 堀越 誠一郎
Seiichiro HORIKOSHI

1. はじめに

先行研究¹⁾では、名古屋市庄内川流域を対象にセマンティックセグメンテーションによる土地利用分類が行われたが、学習対象となる入力データの特性に関する検討は十分になされていなかった。

本報告では、DeepLabV3+²⁾を用い、入力画像の空間的範囲の違いが分類精度に与える影響と、学習データセットの枚数増加による有効性について検証を行う。

2. 学習手法とデータ

2.1 学習モデル

本報告における深層学習モデル構築手順を以下に示す。まず、学習に用いる航空写真および対応する土地利用分類データを取得、分割することで学習データセットを構築した。次に、モデル構造、ハイパーパラメータ、学習条件を設定し学習を実行した。その後、得られた結果を評価し、必要に応じてモデルおよびデータの修正を行った。

深層学習モデルには、物体のエッジ抽出精度に優れる DeepLabV3+ を採用した。図-1 に対象地域である愛知県名古屋市庄内川地域および東京都荒川下流地域を示す。バックボーンは ResNet を使用している。開発環境は、ハードウェアとして CPU: AMD Ryzen 7 5700X, GPU: NVIDIA GeForce RTX 4060Ti, RAM: 32GB を使用し、ソフトウェア環境は Windows 11 Pro, Anaconda3 (Python 3.9, PyTorch 2.8.0) である。

2.2 学習データ

学習データとして、PLATEAU の土地利用分類データ（正解ラベル）と、入力画像には国土地理院地理院タイル（標準地図）を用いた。クラスは「建物、田畑、山林、河川、道路」の 5 クラスとした。また、学習データは学習用と検証用に 8:2 に分割して用いた。

入力画像の空間的範囲による精度比較を行うため、図-2 の通り以下の 2 Case を設定した。

- Case 1: 範囲 100m × 100m (296px × 296px)
- Case 2: 範囲 200m × 200m (592px × 592px)

庄内川地域では画像枚数が異なる条件(Case 1: 17,082 枚, Case 2: 4,270 枚)で比較し、一方、荒川地域での大規模学習においては、100m 画像を座標基準として 200m 画像を作成することで、両 Case の画像枚数を統




図-1 対象地域 庄内川地域 (左), 荒川地域 (右)




図-2 作成した学習データ

一 (各 21,093 枚) した。これは元画像を重複させて切り出したものであり、学習データ枚数は増加するが、データが持つ情報の多様性は増加していない。表-1 にモデルの学習条件を示す。

2.3 評価指標

学習 1 では庄内川地域のデータを学習、荒川地域のデータで推論評価し、学習 2 では荒川地域のデータを学習、庄内川地域のデータで推論評価した。定量的評価の指標には、学習時は学習曲線 (Training Accuracy, Validation Accuracy. 以下, Train Accuracy, Val Accuracy と表記) を用い、推論時は Test Accuracy, IoU (Intersection over Union) 値および混同行列 (再現率, 適合率, Macro F1 score) を用いる。

表-1 学習条件

項目	設定値
バッチサイズ	16
中間層	50 層
学習回数	50 回
損失関数	交差エントロピー誤差
活性化関数	ReLU 関数

3. 結果と考察

表-2 に Test Accuracy を示す。両学習で Case1 が高い正解率を示し、学習 2/Case1 の正解率が最高値となった。また、画像枚数の増加に伴う正解率の向上が確認された。

図-3 に IoU 値による評価を示す。両学習で Case 1 が高い精度を示した。Case 間の IoU 減少量は、特に建物・道路において大差なく、画像重複により特徴量変化がない場合は、pixel 量の倍化は精度向上に寄与しないと推定できる。また、画像枚数の増加は画像サイズによる精度変動に影響していないと考えられる。

表-3 に学習 1 の混同行列を示す。F1 score および再現率、適合率について Case 間に大差はない。ただし、山林の適合率は 26% 上昇しており、山林の誤分類 pixel 数は大幅に減少している。山林の予測割当数が 1/3 に減少したことから、判定が厳格化したといえる。これは、母数の多い建物の分類精度が向上した影響と考えられる。実際、建物の再現率は 90% を超え (Case2 で 98.3%)、ほぼ正解できている。

表-4 に学習 2 の混同行列を示す。全体精度である F1 score は Case1 のほうが約 6.9% 高い値を示した。一方、山林の再現率が Case1、2 共に 0% になっており、山林ラベルの予測数から見て山林への分類がおこなわれていないことがわかる。重みの学習時点で山林の分類を全く行わない場合の精度が高くなっていると推察できる。これは、荒川地域の山林画素割合が 2.61% (庄内川は 9.94%) と極端に低く、データ不均衡により山林を無視する方が全体の損失が下がるためと推察される。

図-5 に学習 2 推論出力結果を示す。道路の境界や微小な田畑の抽出において、100m 画像は 200m 画像よりも高い認識精度を示した。200m 画像では道路の境界が曖昧になり細く分類されやすく、その間隙が建物として誤分類される傾向が強い。

4. おわりに

本報告では、入力画像の空間的範囲の違いが分類精度に与える影響と、学習データセットの枚数増加について検証を行い、以下の結論を得た。

- 入力画像の空間的範囲に関して、1 辺 100m の入力画像が 200 m のものに比較して高い精度を示した。
- 入力データ枚数増加で正解率向上が確認された。

特徴情報の総量に変化しない単純な画素数の増加は、精度向上に寄与しないことが示唆された。また、データセット内のクラス分布の偏りが少数クラスの分類精度に著しい影響を与えることが確認された。

今後の課題として、ハイパーパラメータの与える影響について検討をおこなうことが挙げられる。また、学習ラベル分布が均等な地域で学習をおこなう必要がある。

表-2 Test Accuracy

	学習1 庄内川学習, 荒川推論	学習2 荒川学習, 庄内川推論
Case1(100m×100m)	0.699	0.7915
Case2(200m×200m)	0.665	0.6207




図-3 Test IoU


表-3 混同行列 (学習 1)

Case1 100m	建物	田畑	山林	河川	道路	再現率
建物	1185410883	25242194	10840179	2751087	12268381	95.9%
田畑	88074369	19989991	5662268	419895	744375	17.4%
山林	8921600	668125	317747	53347	12721	3.2%
河川	51545636	22073973	705594	14276701	434094	16.0%
道路	315062408	7704476	226624	2584189	72088881	18.1%
適合率	71.9%	26.4%	1.8%	71.1%	84.3%	F1: 35.7%
Case2 200m	建物	田畑	山林	河川	道路	再現率
建物	157390383	2479064	1869592	46996	1511424	96.4%
田畑	2718050	962286	370417	745	37648	23.5%
山林	8706505	5304059	8285415	162833	123808	36.7%
河川	2312042	996895	715447	1958370	25170	32.6%
道路	58388781	2032732	1507439	60396	8911839	12.6%
適合率	68.6%	8.2%	65.0%	87.8%	84.0%	F1: 33.9%

表-4 混同行列 (学習 2)

Case1 100m	建物	田畑	山林	河川	道路	再現率
建物	889082426	29490566	1817	2224629	30608753	93.4%
田畑	85595638	51190918	1366	2312051	12904783	33.7%
山林	24728183	13871889	2662	1721599	442856	0.0%
河川	3389867	2980650	203	29547573	152928	81.9%
道路	93640068	7313969	1089	609463	214840566	67.9%
適合率	81.1%	48.8%	37.3%	81.1%	83.0%	F1: 52.7%
Case2 200m	建物	田畑	山林	河川	道路	再現率
建物	228634493	5740712	0	509037	7086318	94.5%
田畑	23774939	11106244	206	219320	1103091	30.7%
山林	4634912	4628661	82	289085	111625	0.0%
河川	1622535	479315	0	6565044	134056	74.6%
道路	40010545	1463138	0	65481	32787305	44.1%
適合率	76.5%	47.4%	28.5%	85.8%	79.5%	F1: 45.8%

表-5 推論結果 (学習 2)



参考文献

- 1) 大館雄介, 羽物裕人, 大川博史, 樫山和男: PLATEAU を活用した深層学習による土地利用分類精度向上の検討, 計算工学講演会論文集, Vol. 30 (2025 年 6 月)
- 2) Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H.: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, Proceedings of the European Conference on Computer Vision (ECCV), pp. 801-818, 2018.

不連続 Galerkin 法に基づく p -Adaptive 解析手法の構築Development of p -Adaptive Discontinuous Galerkin Method都市環境学科 4 年 木村 伊吹
Ibuki KIMURA

1. はじめに

不連続 Galerkin 法 (Discontinuous Galerkin: DG) は、衝撃波などの不連続性を伴う現象に対して極めて有効な数値解析手法である。古典的な有限要素法は、要素境界において解の連続性 (C^0 級) を要請するため、衝撃波のような急峻な変化を伴う不連続解の近傍で数値振動 (ギブス現象) が生じやすい。これに対し、DG 法は要素間での物理量の不連続性を許容し、数値フラックスを介して要素間の情報を伝達するため、不連続面を安定かつ高精度に捉えることが可能である。

また、DG 法は各要素が独立して計算される性質を持つため、局所的な近似次数の変更 (p -Adaptive) といった適応的な制御が容易であるという利点を有している。特に p -Adaptive 手法は、解の勾配が急峻な領域には高次近似を、平滑な領域には低次近似を動的に割り当てることで、全体の計算効率を向上させることが期待できる。

そこで本研究では、DG 法に基づく一次元 p -Adaptive 解析手法の構築を目的とする。数値解析例として線形移流方程式および非線形の Burgers 方程式を用い、要素境界における解のジャンプ量に基づく誤差指標によって近似次数を動的に制御するアルゴリズムの妥当性を検証する。さらに、固定次数での解析結果との比較を通じて、提案手法の計算精度および計算コストの削減効果に関する定量的な評価を行う。

2. 支配方程式

本研究では、線形問題として一次元線形移流方程式を、非線形問題として Burgers 方程式を対象とする。

2.1 線形移流方程式

一次元線形移流方程式は、移流速度を a として次式 (1) で表される。

$$\frac{\partial u}{\partial t} + a \frac{\partial u}{\partial x} = 0, (L_0 \leq x \leq L_1, t > t_0) \quad (1)$$

本式においてフラックス関数は $f(u) = au$ となる。数値フラックスに Local Lax-Friedrichs flux を用いた場合、 $\alpha = |a|$ となり風上フラックスと等価になる。

2.2 Burgers 方程式

一次元 Burgers 方程式は、式 (2) で表される。

$$\frac{\partial u}{\partial t} + \frac{\partial f(u)}{\partial x} = \nu \frac{\partial^2 u}{\partial x^2}, (L_0 \leq x \leq L_1, t > t_0) \quad (2)$$

ここで、 u は未知量、 ν は動粘性係数である。また、 $f(u)$ はフラックス関数であり、 $f(u) = u^2/2$ とする。

3. Local Discontinuous Galerkin 法

ここでは、Local Discontinuous Galerkin (LDG) について詳細を述べる。前述の支配方程式 (2) に対して補助変数 $\sigma = \sqrt{\nu} \frac{\partial u}{\partial x}$ を導入し、式 (2) の再構成を行う。

$$\frac{\partial u}{\partial t} + \frac{\partial f(u)}{\partial x} - \sqrt{\nu} \frac{\partial \sigma}{\partial x} = 0, (L_0 \leq x \leq L_1, t > t_0) \quad (3)$$

$$\sigma - \sqrt{\nu} \frac{\partial u}{\partial x} = 0, (L_0 \leq x \leq L_1, t > t_0) \quad (4)$$

3.1 空間方向の離散化

解析領域 $[L_0, L_1]$ を N 個の要素に分割する。解関数と重み関数の空間は、直交基底により要素上で定義する。直交基底関数として、Legendre 多項式を用いる。数値解 u_h は、以下のように基底関数 $P_k(\xi)$ を用いて表す。

$$u_h(\xi, t) = \sum_{k=0}^p \hat{u}_k(t) P_k(\xi) \quad (5)$$

ここで、 p は多項式次数、 $\hat{u}_k(t)$ はモード係数である。

式 (3) と式 (4) に、それぞれ重み関数 v, ϕ を乗じ、弱形式 (6), (7) を得る。

$$\int_K v \hat{u} + [v \hat{f}] - \int_K v' f - \sqrt{\nu} [v \hat{\sigma}] + \sqrt{\nu} \int_K v' \sigma = 0 \quad (6)$$

$$\int_K \phi \sigma - \sqrt{\nu} [\phi, \hat{u}] + \sqrt{\nu} \int_K \phi' u = 0 \quad (7)$$

また、"hat" 記号が付く項は数値フラックスであり、要素境界上の 2 点の値から一意に定まる関数である。ここでは、移流項に関する $\hat{f}$ と、拡散項に関する $\hat{u}, \hat{\sigma}$ の 2 種類の数値フラックスが定義可能である。

3.2 数値フラックス

拡散項による数値フラックスは、次式 (8), (9) で与えられる。

$$\hat{u} = 0.5(u^+ + u^-) + C_{12}(u^- - u^+) \quad (8)$$

$$\hat{\sigma} = 0.5(\sigma^+ + \sigma^-) - C_{11}(u^- - u^+) - C_{12}(\sigma^- - \sigma^+) \quad (9)$$

ここで、 $C_{11} = 0, C_{12} = 0.5$ or -0.5 のとき、Alternating flux となる。また、 $C_{11} = C_{12} = 0$ のとき、Central flux となる。

本研究では、移流に関する数値フラックスは、次式 (10) に示す、Local Lax-Friedrichs flux を採用する。

$$\hat{f}(u^-, u^+) = \frac{f(u^-) + f(u^+)}{2} - \frac{\alpha}{2}(u^+ - u^-) \quad (10)$$

$$\alpha = \max |f'(u)| \quad (11)$$

Local discontinuous Galerkin 法は、質量行列の逆行列を求めることのみで、補助変数 σ を陽的かつ局所的に解き、全体ベクトル U に関する常微分方程式系を導くことが可能な手法である。

$$\frac{dU}{dt} = \mathcal{L}(U) \quad (12)$$

3.3 時間方向の離散化

時間積分には、次式の 3 段階 3 次精度 ($s = k = 3$) SSP Runge-Kutta 法を用いる。

$$U^{(1)} = U^n + \Delta t \mathcal{L}(U^n)$$

$$U^{(2)} = \frac{3}{4}U^n + \frac{1}{4}U^{(1)} + \frac{1}{4}\Delta t \mathcal{L}(U^{(1)}) \quad (13)$$

$$U^{n+1} = \frac{1}{3}U^n + \frac{2}{3}U^{(2)} + \frac{2}{3}\Delta t \mathcal{L}(U^{(2)}) \quad (14)$$

4. Adaptive p -Refinement

4.1 p -Refinement

本研究で採用した Legendre 多項式のような階層型基底関数を用いる場合、次数の変更は式 (5) におけるモード係数の係数ベクトルのサイズ変更のみで実行可能である。つまり、次数を増加させる場合は新たな高次項の係数をゼロとして追加し、減少させる場合は既存の高次項を切り捨てることで、再計算なしに L^2 射影による近似解が得られる。

4.2 誤差指標

本研究の p -Adaptive 解析における誤差指標には、Remacle¹⁾の提案に基づき、要素境界における不連続量に着目する。多次元に一般化すると、要素 K の誤差 ϵ_e は、次式 (15) で与えられる。

$$\epsilon_e = \sum_{i=1}^{n_k} \int_{\partial K} |u^+ - u^-| d\Gamma \quad (15)$$

ここで、 n_k は要素の辺の数である。特に、対象を一次元問題に限定すれば、より簡素な (16) 式が得られる。(図 1)

$$\epsilon_e = |u_e(x_{i+1}) - u_{e+1}(x_{i+1})| + |u_e(x_i) - u_{e-1}(x_i)| \quad (16)$$

4.3 適応アルゴリズム

次ステップの適応次数 p_e は各要素ごとに式 (17) で与えられる。

$$p_e = \max(p_{\max} - i, 1) \quad (17)$$

ここで、 $p_{\max}$ は許容最大次数、 i は式 (18) で決定される要素レベルを指す整数である。

$$\frac{\epsilon_{\max}}{d^{i+1}} \leq \epsilon_e < \frac{\epsilon_{\max}}{d^i} \quad (18)$$

ここで、 $\epsilon_{\max}$ は全要素中の最大値である。 d は任意のパラメータであり、この値が大きいほど誤差を敏感に検知し、より高次の次数が適応される。




図-1 一次元問題における誤差指標の概略図

5. 数値解析例

構築したソルバを用いて、線形移流問題および非線形問題 (Burgers 方程式) の解析を行い、提案手法の検証を行う。

5.1 線形移流問題

5.1.1 解析条件

解析領域は $x \in [0, 10]$ とし、両端には周期境界条件を課す。また、移流速度 $a = 1.0$ 、微小時間ステップ $\Delta t = 1.0 \times 10^{-3}$ とし、終了ステップ数は 8000 とする。さらに、適応アルゴリズムにおける初期次数 $p_{ini} = 1$ 、最大次数 $p_{\max} = 3$ 、閾値パラメータ $d = 50.0$ と設定する。初期条件 $u_0(x)$ は、式 (19) に示す矩形分布とする。

$$u_0(x) = \begin{cases} 1.0 & (1.5 \leq x \leq 3.5) \\ 0.0 & (\text{otherwise}) \end{cases} \quad (19)$$

上記の条件で、要素数 $N = 50, 100, 200, 500$ の計 4 つの等間隔メッシュを用いてケーススタディを行う。なお、本例題では、全要素で固定次数 ($p = 1, 2, 3$) の解析と Adaptive 解析で比較を行う。

5.1.2 解析結果

まず、図 2 に $N = 100$ としたときの、4000 ステップ目における厳密解と解析結果を示す。この結果から、高次要素を用いた方が厳密解に近い形状を表現できていることがわかる。

次に、図 3 に $N = 100$ としたときの Adaptive 解析の結果を示す。変化の大きい不連続解の近傍のみに高次 ($p = 2, 3$) が、その他は低次 ($p = 1$) が適用されており、解の挙動に応じた近似次数の自動制御が確認できる。

そして、図 4、図 5 に、各解析の L^2 誤差と計算時間を示す。両図より、Adaptive 解析では、より低い計算コストで $p = 3$ と同等の精度を達成でき、割合にして約 36% の計算効率化が図られた。

5.2 非線形問題 (Burgers 方程式)

5.2.1 解析条件

解析領域を $x \in [0, 1]$ とし、両端には境界条件として $u(0, t) = u(1, t) = 0$ を課す。また、微小時間ステップは $\Delta t = 5.0 \times 10^{-5}$ とする。要素数 $N = 10, 25, 50$ の等間隔格子を用いてケーススタディを行う。さらに、適応アルゴリズムにおける初期次数 $p_{ini} = 3$ 、最大次数




図-2 線形問題：固定次数 $p=1, 2, 3$ ($N = 100$)




図-3 線形問題： p -Adaptive ($N = 100$)




図-4 線形問題：最終ステップの L^2 誤差

$p_{\max} = 3$, 閾値パラメータ $d = 10.0$ と設定する。初期条件 $u_0(x)$ は、式 (20) に示す。

$$u_0(x) = \sin(\pi x), (0 \leq x \leq 1) \quad (20)$$

全要素で固定次数 ($p = 1, 2, 3$) の解析と p -Adaptive 解析で比較を行う。

5.2.2 厳密解の算出

この初期値・境界値問題に対する厳密解は、以下の無限級数を用いて表される。

$$u(x, t) = 4\pi\nu \frac{C}{D + E} \quad (21)$$

ここで、各項 C, D, E は次式で定義される。

$$C = \sum_{n=1}^{\infty} n I_n \left(\frac{1}{2\pi\nu} \right) \sin(n\pi x) \exp(-n^2 \pi^2 \nu t) \quad (22)$$

$$D = 2 \sum_{n=1}^{\infty} I_n \left(\frac{1}{2\pi\nu} \right) \cos(n\pi x) \exp(-n^2 \pi^2 \nu t) \quad (23)$$

$$E = I_0 \left(\frac{1}{2\pi\nu} \right) \quad (24)$$




図-5 線形問題：適応化による計算コストの削減効果




図-6 Burgers 問題：Uniform $p = 3$ ($N = 25$)

ただし、 $I_n(x)$ は第 1 種変形ベッセル関数である。なお、厳密解の数値的な算出にあたっては、無限級数の和を第 50 項 ($n = 50$) で打ち切った値を採用する。

5.2.3 解析結果

以下、得られた結果について述べる。まず、図 6 と図 7 に $N = 25$ の、固定次数 $p = 3$, Adaptive 解析のそれぞれの結果を示す。黒のプロットは、式 (21) によって算出された各時間ステップにおける厳密解である。両図の比較より、解の挙動に応じた近似次数の自動的な制御が確認できる。特筆すべきは、時間発展に伴い衝撃波が生じる右端近傍の要素に対して、最高次数 ($p = 3$) が局所的に割り当てられていることである。

次に、図 8, 図 9 に、各条件の L^∞ 誤差と計算時間を示す。両図より、Adaptive 解析では、より低い計算コストで固定次数 $p = 3$ とほぼ同等の精度を達成でき、計算効率化が図られた。

最後に、図 10 について述べる。誤差を総自由度の関数としてプロットすることで、 h -, p -収束特性に関する結果について、同一のグラフ上で比較・検討が可能となる。固定された次数でのメッシュ細分化による効果を点線で、メッシュサイズを固定し近似次数を高次化した際




図-7 Burgers 問題 : p -Adaptive ($N = 25$)




図-10 h -, p -convergence study




図-8 Burgers 問題 : 誤差のメッシュ依存性




図-9 Burgers 問題 : 適応化による計算コストの削減効果

の収束特性を黒の実線でそれぞれ示している。同じ自由度で比較すると、高次近似を用いる方が誤差がより小さくなっていることがわかる。

陽解法を用いる場合、計算コストは自由度にほぼ比例するため、メッシュを細分化するよりも近似次数を高次化の方が計算効率に優れているといえる。少なくとも本研究の対象とした問題においては、より少ない計算

コストで同等の解析精度が得られることが確認できた。

6. おわりに

本報告では、不連続性を伴う現象に対する高精度解析手法として、DG 法に基づく p -Adaptive 解析に着目し、一次元問題を対象にソルバの構築を行った。そして、以下の結論を得た。

- 解の変動に応じた近似次数の動的制御が機能していること確認した。
- p -Adaptive 解析により、計算コストを抑えつつ固定次数条件と同等の精度が得られる。
- 陽解法の計算時間は自由度にほぼ依存するため、多次元解析においても高い計算効率化が期待できる。

今後は、多次元問題への拡張、誤差指標における閾値や動粘性係数のパラメータスタディが課題として挙げられる。

参考文献

- 1) Remacle, J.-F., Flaherty, J. E. Shepard, M. S. (2003). An adaptive discontinuous Galerkin technique with an orthogonal basis applied to compressible flow problems. SIAM Review, 45(1), 53-72.
- 2) Ethan Kubatko, Development, Implementation, and Verification of HP Discontinuous Galerkin Model for Shallow Water Hydrodynamics and Transport, The University of Notre Dame, 2005.
- 3) Li, Ben Q. Discontinuous Finite Elements in Fluid Dynamics and Heat Transfer. Springer, 2006.
- 4) Gottlieb, Sigal. "On high order strong stability preserving Runge-Kutta and multi step time discretizations." Journal of scientific computing 25.1 (2005): 105-128.