

## 空間的不均一性・連続性に関する正規化処理による 地すべり移動体の深層生成

### Deep generative model of landslide mass using spatial non-uniformity and continuity of landslides

竹内祐太郎\*・山本 義幸\*\*・古木 宏和\*\*\*

宇津木慎司\*\*\*\*・吉田 一也\*\*\*\*\*・中村 吉男\*\*

*Yutaro TAKEUCHI, Yoshiyuki YAMAMOTO, Hirokazu FURUKI  
Shinji UTSUKI, Kazuya YOSHIDA and Yoshio NAKAMURA*

**Abstract:** Landslide map is a thematic map used for disaster management. In recent years, there have been attempts to create landslide maps using artificial intelligence-based approaches. This study aimed to clarify the effectiveness of two normalization methods, derived from the spatial non-uniformity and continuity of landslide topography, for the deep generative model of landslide moving mass. We propose a normalization method for the supervised data to correct the spatial non-uniformity of landslides. The resulting supervised data, normalized by landslide area occupancy, improved the learning efficiency of the deep generative model. We also propose a normalization method for the inferred results using the spatial continuity of landslides. The inferred results, post-processed by employing our normalization method, showed reasonable distribution in comparison to the ground truth.

#### 1. はじめに

地理空間情報分野においては、従来から、様々なテーマ（主題）からなる主題図が重要なコンテンツとなっている。主題図は、土地利用図など、あるテーマにかかわる場所を具体的に示したもので、様々な計画・設計や社会生活にかかわる基礎資料として利用されている。例えば、防災に関わる主題図は、防災計画や住民個々の命を守る行動のために有用である。防災に関わる主題図の一つに、地すべり地形分布図（大八木ら、2015）がある。これは、空中写真から専門家によって判読された地すべり地形の分布状況をとりまとめたものである。

地すべり発生箇所は、現在滑動が進行しているものはもとより現在滑動が休止状態であったとしても、将来的に再滑動や崩壊等が起きやすい。よって、地すべり地形分布図から得る地すべり地形の位置は、防災対策を講ずるにあたって有用な情報となる。地すべり地形分布図（大八木ら、2015）は、専門家の知見をもとに空中写真を判読して、作成されている。専門家は、各々固有の経験知を持っていて、その多くは図化や言語化が難しい。したがって、地すべり地形分布図は、防災面での有用性を有す一方で、作成担当の専門家ごとで地すべり地形の形・大きさ・数が異なるといった不確実性を有している（佐藤ら、2018）。なお、これは、他の主題図、例えば、同様に空中写真を判読して作成される植生図などでも見られる。

近年、この地すべり地形分布図を AI（Artificial Intelligence：人工知能）で作成する試みが行われている（古木ら、2019）（古木、2021）（荒木、2019）（野呂ら、2018）。地すべり地形分布図は、従来、空中写真の実体視で地形の三次元像を想像し、手書きで作成される。AI は、画像の特徴理解を得意としており、これによる画像分類・生成が社会実装され始めている。同様

\* 愛知工業大学大学院工学研究科博士前期課程建設システム工学専攻

\*\* 愛知工業大学土木工学科

\*\*\* 日本工営株式会社中央研究所

\*\*\*\* UGS

\*\*\*\*\*株式会社アイコ地質調査部

「写真測量とリモートセンシング」VOL. 61, NO. 1, 2022

に、AIで地すべり地形分布図を作成すると、地形の三次元情報を格納した画像が必要となる。これにおいて、先行研究(古木, 2021)はCS立体図(戸田, 2014)を利用した。CS立体図は、DEM(Digital Elevation Model: 数値標高モデル)データから地形の凹凸を分かりやすく強調しカラー表示している。このCS立体図から地すべり地形(地すべり移動体)を出力するAI(深層生成モデル)が学習により作成された。AIは、定型の大きさの画像(教師データ)を複数枚使用して、目標(正解)の出力となるように学習する。その際、教師データの偏りが学習の妨げになることがある(岡谷, 2019)。先行研究(古木, 2021)は、専門家の知見で、CS立体図の色調の偏りを地すべり地形の特徴を強調するように鮮鋭化する正規化手法でAIの性能を向上させている。

地すべり地形を深層生成モデルの対象とする場合、他の一般的な対象とは異なり、二つの偏りが考えられる。一つ目は、教師データの画像における、地すべり地形のサイズの偏りである。一般に、深層生成モデルは、教師データの各画像上での対象物を同程度のサイズにそろえ効率的に学習する。しかしながら、地すべり地形のサイズは不均一である(空間的不均一性)ため、教師データは、同程度のサイズばかりでそろえられない。また、先行研究(例えば、Hendrycks, D, 2021)において、画像内の対象物のサイズが小さい場合に、多くの面積を占めている非対象物の特徴を評価し誤分類する結果が報告されている。このことなどから、特に、空間的不均一性を有している地すべり地形のデータセットにおいて対象物の面積占有率が誤出力の原因となる可能性が懸念される。二つ目は、深層生成モデルからの出力の偏りである。これは、一つ目の偏りに起因する側面もあるが、深層生成モデルが、教師データの地すべり地形(地すべり移動体)のサイズに応じた学習をし、そのように出力する特性である。即ち、地すべり地形の大きなサイズの教師データで学習した深層生成モデルは、地すべり地形の小さなサイズのところでも、大きく出力する可能性がある。よって、地すべり地形分布図の深層生成は、この地すべり地形の空間的不均一性に起因する二つの偏りを是正することで、効率的な学習と高い精度の出力を可能にするものと考えられる。

AIの分野は、一般に、データを正規分布に従わせる(画像の色成分をあらかじめ定義した平均と標準偏差

で正規化するなど)といった正規化で偏りを是正する。上述の空間的不均一性に起因する一つ目の偏り(地すべり地形のサイズの偏り)を是正する一つの方策として、地すべり地形(地すべり移動体)の面積占有率による教師データの正規化が考えられる。この教師データの正規化によって、面積占有率を基準とした、教師データセットの画像枚数構成が図られ、地すべり地形の出力サイズの偏りが是正されると考えられる。二つ目(深層生成モデルからの出力の偏り)は、複数回出力させて、その出力頻度で是正される可能性がある。地すべり地形分布図の深層生成は、概ね、ある程度の広い範囲を対象とする。よって、深層生成モデルへの入力対象範囲を分割した画像となるが、この分割画像は、両隣が連担しており、空間的連続性を有するものとなる。そのため、分割画像を深層生成モデルに入力して、推論(出力)した結果を再結合もできる。この空間的連続性を利用し、分割画像の作成にあたって、重複領域を有するようにスライドして分割し、取得した画像のデータセットを複数用意する。それらを学習済みの深層生成モデルに入力することで、同一箇所(重複領域)を推論した画像が複数枚にわたって出力される。そして、深層生成モデルからの出力の偏りは、この複数枚にわたる出力の頻度で正規化することで、是正される可能性がある。

以上で提案する正規化手法は、機械的な処理であるため、先行研究(古木, 2021)と異なり、専門家の知見を必要としない長所を有するが、深層生成の不確実性を考えると、これで十分な結果が得られるとは考えづらい。しかしながら、正規化処理によって出力の精度を高めることは可能ではないかと考える。また、上記のように不確実性を有す地すべり地形を教師データとして学習して出力される結果であることから、高精度での地すべり地形の出力は難しいものとする。そこで、出力結果の後処理で正規化を施す際に、確からしさの幅(ゆらぎ)を考慮することで、土砂移動にかかわる地形を抽出し、後に、専門家に判断を委ねる一次資料程度の結果は得られるのではないかと考える。

本研究は、地すべり移動体の深層生成において、地すべり地形の空間的不均一性・連続性に関わる2つの正規化手法を提案し、その有効性を明らかにする。この有効性を明らかにするために、次の2つの目的を設定した。

1. 地すべり地形の空間的不均一性からなる教師デー

タの偏りを、地すべり移動体が画像中に存在する割合（面積占有率）で正規化した深層生成モデルの性能評価

## 2. 検証データの空間的連続性を活用した出力結果の後処理正規化手法の有効性評価

また、この正規化による出力結果が、専門家が地すべり地形を判読する際の一次資料としての有用性を有すかについても評価する。なお、今回の深層生成では、滑落崖や微地形の情報は使用する分解能（1ピクセル10m四方）では画像上に現れにくいと考えられ生成対象とは扱わず、上述の通り地すべり移動体のみを対象としている。ただし、3.1でも述べるが、地すべり移動体の深層生成は、正解データ作成の都合上、地すべりの詳細なブロック分けまでを可能とする性能は前提としていない。

## 2. 先行研究と本研究の位置づけ

一般的な深層学習は、CIFAR-10 (Krizhevsky, A., 2009) のように学習対象が画像の中心付近にかつ大きく描写された空間的均一性を有す画像で学習をする。しかし、今回扱う地すべり地形は、箇所単位（パッチサイズ）の形・大きさが不均一である。そのため、地すべり地形のサイズが揃った空間的均一性を有す教師データセットは収集しづらい。

さらに、一般的な深層生成では、pix2pix (Isola, P. et. al., 2016) のような検証データで用いる画像の内容は、空間的にそれぞれが独立しており、推論結果も各単画像のみで完結できる。一方で、地すべり地形の推論は、検証データのある程度の範囲の画像から分割して作成するという空間的連続性を有す特徴がある。

図1に、先行研究と本研究の大まかな流れをフロー形式での比較を示す。先行研究 (古木, 2021) において、教師データの画像の鮮鋭化が、深層生成モデルからの地すべり地形の推論において有効であることが示されている。また、見切れている地すべり移動体を除外して、抽出精度を向上させた。

これに対して、本研究は、図1に示すように地すべり地形の空間的不均一性・連続性において、機械的に行える、教師データ・検証データの正規化が地すべり移動体の推論結果を向上させられるかに着目している。

そこで本研究では、学習データ作成の難易度を下げ



図1 先行研究 (古木, 2021) と本研究の比較

るために、専門家の知見を持たずとも、空間的不均一性に着目した面積占有率で正規化した教師データセットを作成する。これを学習させた後に、空間的連続性を利用して、スライド処理をした複数の重複領域を有する検証データを使用して、深層生成による地すべり移動体を出力する。それを重ね合わせ、出力頻度による正規化を行い、出力結果を検証し、提案する正規化手法の有効性を明らかにするものである。

## 3. 使用データと対象エリア

地すべり移動体を深層生成で出力させるために、先行研究 (古木ら, 2019) でも使用された「地すべり地形分布図 (防災科学技術研究所, 2002)」と「CS立体図 (長野県, 2021確認)」を使用して、教師データ・検証データを作成した。対象エリアは、愛知・岐阜・静岡・三重にわたる、1次メッシュコードの5237の範囲とした。図2には、対象エリアの地質図 (産総研地質調査総合センター, 2021確認)・CS立体図・地すべり移動体を示す。なお、地質図は、地質図Navi (産総研地質調査総合センター, 2021確認) を使用し、著者が対象エリアを切り出し、凡例を加筆したものである。

### 3.1 地すべり地形分布図

地すべり地形分布図（防災科学技術研究所，2002）は，防災科学技術研究所（以下，防災科研と称す）が作成したものを使用した。図3に防災科研の地すべり地形分布図の一例を示す。地すべり地形は，主に，斜面を移動した土砂でなだらか（緩斜面）な領域に位置する地すべり移動体（図3（左）中茶色のポリゴン）と，その周辺の斜面に残った崖（急斜面）からなる滑落崖（図3（左）黒色ライン）で構成される。図3（右）は，地すべりの描画例である。地すべり地形は，空中写真から滑落崖に注目して判読される。しかしながら，深層生成の対象は，線状の認識が難しいため，面状の地すべり移動体とする。

地すべり地形分布図は，防災科研の GIS データ 1：50,000地すべり地形分布図（防災科研，2002）（図名：豊橋）を使用した。これは，1970年代に撮影された撮影縮尺4万分の1のモノクローム空中写真を倍率4倍の簡易実体鏡を用いて判読した地すべり地形をデジタル化したものである。ただし，幅150m以上の比較的大

規模な地すべり地形のみを抽出している。この分布図には，滑落崖を表すラインと地すべり移動体を表すポリゴンが描かれている。本研究では，地すべり移動体の輪郭・境界のうち「後方に滑落崖があり，移動体の輪郭が明瞭ないし判定可能」のポリゴンをラスタ化（1ピクセル10m四方）し，図2右のような地すべり移動体の正解データ（以下，正解）とした。なお，図3では連担している地すべり移動体がブロック分けされているが，図2右のように正解データの地すべり移動体は，ブロックごとで色分けはせず，一色（黒色）としている。そのため，連担する地すべり移動体のブロック分けされた情報は結果的に無視され，一塊として学習される。よって，今回の深層生成では，連担する地すべり移動体の細かなブロック分けを行う性能は担保できないものと考えられる。さらに，この GIS データは，現地調査を実施していないため「地すべり地形が表示されていない」と「地すべりや地すべり地形が存在しない」は同義でない（大八木ら，2015）と明記されており，上述のとおり不確実性を有している。

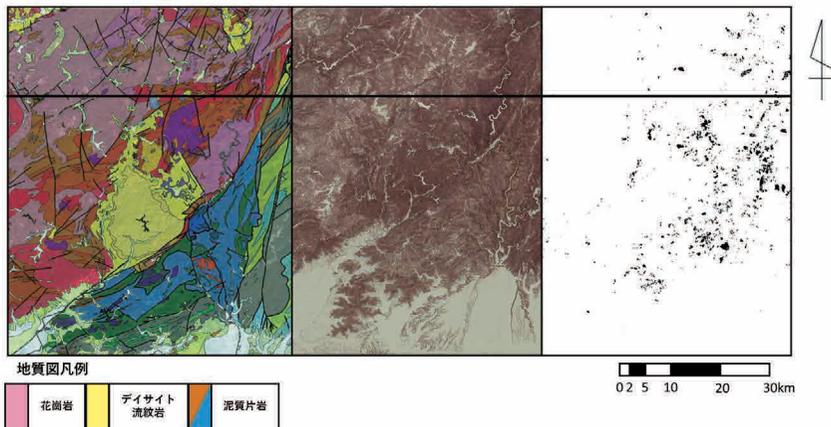


図2 対象エリアの地質図（左）・CS立体図（中）・地すべり移動体（右）

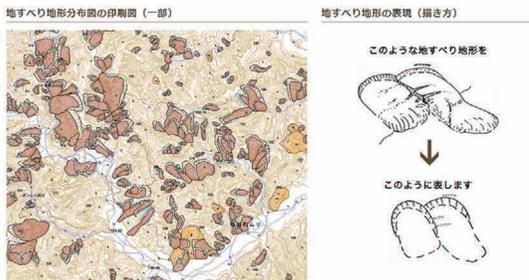


図3 滑落崖の表示をした地すべり地形分布図（大八木ら，2015）より引用

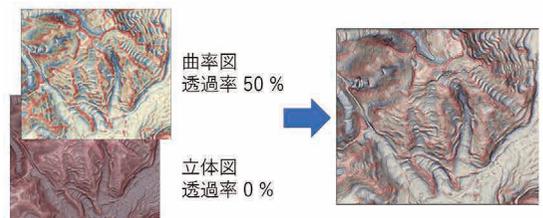


図4 CS立体図の作成（長野県，2021確認）の図を編集

### 3.2 CS 立体図

CS 立体図は、図 4 のように、従来の陰影図法とは異なり、光源や視点の位置の影響を受けることなく立体を表現する図法で描かれた地形図の一種である(戸田, 2014)。また、CS 立体図は、作成プラグインがオープンソース化されており傾斜量と曲率をパラメータとして、地形の起伏、傾斜量を同時に表現する立体表現図である(古木, 2021)。このことから、取得が容易であり、かつ尾根・谷など地すべり判読に有効な地形が等高線による地形図よりも詳細に表現され、先行研究(古木, 2021)でも利用されていることから採用した。

深層生成モデルの入力データは、G 空間情報センターから長野県林業総合センターが作成した全国\_CS 立体図\_10m\_07(図名: 52373~52374)を使用した。図 4 のように、CS 立体図は、10m メッシュの DEM データから標高・傾斜・曲率を計算し、作成した立体図(透過率 0%)と曲率図(透過率 50%)を重ねて作成される。谷(凹)地形が青色、尾根(凸)地形が赤色、緩斜面を淡茶色、急斜面を濃茶色で段彩化して表示され、地すべり地形は淡白色系~淡銀色系の色調で表示される。

### 3.3 対象エリアの概要

図 2 は、対象エリアの地質図(産総研地質調査総合センター, 2021確認)、CS 立体図、地すべり移動体の位置図である。このエリアの地盤は主に中生代に形成された地盤である。地質的には、西側は、花崗岩・デイサイト・流紋岩の地盤が広がっており、固く安定しているため地すべりは少ない。一方、東側は、泥質片岩の地盤が広がっており、層状に剥がれやすく、地すべりがよく起きる地質であり、地すべり移動体(図 2(右)の黒色の箇所)が広く分布している。

なお、これ以降の CS 立体図、および、地すべり移動体の図は、方位の記載をしていないが、図 2 と同様に紙面上方向が北の配置となっている。

## 4. 地すべり地形に関する空間的不均一性・連続性と提案する正規化手法の関係

本研究は、地すべり移動体の深層生成において、空間的不均一性・連続性に関する正規化手法を提案する。以下に、この手法の提案に至ったアイディアと概念について述べる。

### 4.1 地すべり地形の空間的不均一性と面積占有率による正規化手法

地すべり地形は、一般に、図 2 右のように分布に偏りがあり、空間的不均一性を有している。図 5 は、教師データの各分割画像における地すべり移動体の面積占有率別の画像の枚数構成である(分割画像の取得方法は 5.2 に記載)。分割画像の構成は、指数関数的に、図 6 のような地すべり移動体の面積占有率が低い画像は枚数が多く、図 7 のように高くなるにつれ枚数が少なくなっている。このことから、地すべり移動体の空間的不均一性が示されている。

AI において元来、教師データの偏りは、学習を妨げ

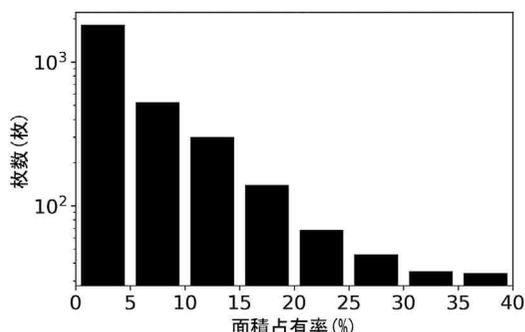


図 5 地すべり移動体の面積占有率別の分割画像(教師データ)の枚数(枚数は対数表示)



図 6 面積占有率の低い地すべり移動体(左)・CS 立体図(右)



図 7 面積占有率の高い地すべり移動体(左)・CS 立体図(右)

る(岡谷, 2019)。そこで、本研究では、教師データを、分割画像中の地すべり移動体の面積占有率で階級分けして、偏り(空間的不均一性)を正規化し是正することで、学習が効率的に行えるのではないかと考えた。先行研究(古木, 2021)では教師データの正規化として、専門家の知見でCS立体図を鮮鋭化し地形を強調することで性能向上が図られ、有効性が示された。これに対して、提案手法は、機械的に処理を行うため、非専門家でも、対応可能な処理である。さらに、この正規化によって不均一な地すべり地形のサイズに対してフレキシブルに対応した出力が期待できる。

#### 4.2 データの空間的連続性による出力結果の正規化手法

地すべり地形の調査は、ある程度の広さの範囲を対象とすることが多い。これを深層生成モデルで扱う際には、対象範囲の画像は分割して入力される。よって、入力される分割画像は、もともと隣で連担していた画像の集まりである。すなわち、空間的連続性を有するもので、出力された画像は再結合が可能である。

上述のとおり、地すべり地形の深層生成では、空間的不均一性・不確実性のため、出力結果に偏りが起きるものと考えられる。それは、例えば、重複領域を含むように分割した画像を入力して、深層生成モデルで出力したとしても、各分割画像の重複領域において、全く同じ出力にはならない現象である。これは、地すべり地形分布図が有する不確実性、ならびに、深層生成モデルの大局的・局所的な処理、地すべり地形の不均一性によるものである。

そこで、上述の偏りを是正するために、地すべり地形分布図およびCS立体図の空間的連続性を利用した出力結果の正規化を行う。深層生成モデルへの入力画像は複数枚の重複領域を有するものとし、その入力画像の重複領域における、複数枚の出力結果を出力頻度で正規化する。即ち、複数枚にわたって出力頻度が高い場所は、学習済みの深層生成モデルが地すべり移動体として判定する確率が高い箇所となる。よって、地すべり地形データ及びCS立体図が有する空間的連続性を利用して、重複箇所を有するようにスライドして分割した画像を深層生成モデルに入力した後に、出力結果を結合・重ね合わせ処理を行い、その出力頻度から推論結果の偏りを正す正規化手法を提案する。

## 5. 正規化手法による地すべり移動体の深層生成と有効性評価

地すべり移動体の深層生成において、上記の概念のような空間的不均一性・連続性に関する正規化手法を提案する。深層生成モデルは、pix2pix(Isola, P. et al., 2016)を使用する。学習データについては、図6、図7のようなペア画像を用いる。以下に、使用した深層生成モデル、空間的不均一性・連続性に関する正規化手法、これらの手法の性能評価方法の詳細を述べる。

### 5.1 深層生成モデル

pix2pixを、CS立体図から地すべり移動体を出力するために使用した。表1に学習パラメータを示す。pix2pixは、GAN(Generative Adversarial Network: 敵対的生成ネットワーク)を利用した画像生成アルゴリズムで、2つのペアの画像から画像間の関係を学習することで、1枚の画像からピクセルサイズの間隔を考慮した補間をしてペアの画像を生成する技術である。GANとは、正解画像に近いフェイク画像を作り出す生成モデルと、与えられた画像が生成モデルの作り出したフェイク画像か正解画像かを見分ける識別モデルの2つのモデルが敵対することで精度を高めていくモデルである。pix2pixは、先行研究(Isola, P. et al., 2016)のように、線画に着色をしたり、馬をシマウマにしたりなど、テクスチャを変換した画像の生成などに利用されている。土木分野でもコンクリートの非破壊検査など実用化に向けた研究が進められている(光谷ら, 2021)。なお、本研究では、次のような仕様のコンピュータを使用した。OS: Windows10, CPU: Intel Core i7-9700F, メモリ: 16GB, GPU: NVIDIA GeForce RTX 2060。

表1 学習パラメータ

教師データ	検証データ	エポック数	バッチサイズ
表2参照	140	200	1

### 5.2 空間的不均一性・連続性を利用した深層生成

空間的不均一性を考慮した教師データの作成(教師データの正規化)・空間的連続性を利用した検証データの作成と出力結果の正規化の方法について以下に示す。

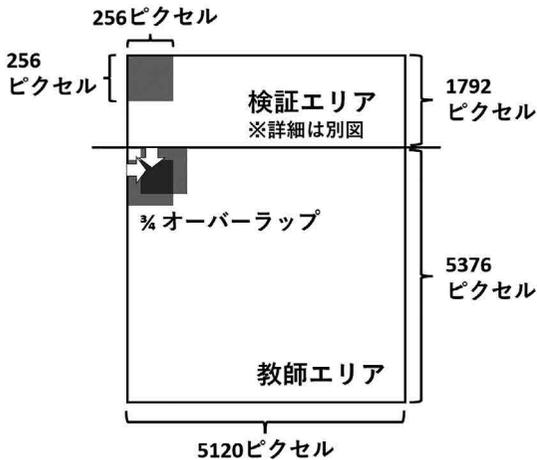


図8 教師・検証データ分割画像の取得方法

図8のように、対象エリアの5120×7168ピクセル(1ピクセル10m 四方)を全体として南側のエリアを教師データ、北側を検証データとした。教師データは、南側から256×256ピクセルで分割して得た420枚、検証データは、北側から同サイズで分割し140枚となる位置までとした。

教師データは、データ拡張および空間的不均一性を考慮した正規化を行う。検証データについては、空間的連続性を利用して出力結果を正規化する。

### 5.2.1 空間的不均一性を考慮した教師データの正規化

地すべり地形のように空間的不均一性に起因する教師データの偏りは、深層生成での学習の妨げになる(岡谷, 2019)ことがある。そこで、教師データセットは、分割画像内の地すべり移動体の面積占有率で階級分けし、各階級の枚数を均等に構成する正規化処理を行った。この提案する正規化処理は、専門的知見がなくても機械的に行える。以下に、この正規化処理方法について述べる。

表2に分割画像の面積占有率で選定したそれぞれの教師データセットの枚数を示す。なお、学習はそれぞれのデータセットで別々に行う。pix2pixで使用する教師データのペア画像は、先行研究(古木ら, 2019)

表2 教師データの枚数

5%以上	10%以上	15%以上	均等
1069枚	508枚	239枚	140枚

と同様に、図8のとおり、画像幅の1/4スライド(3/4オーバーラップ)させるデータ拡張処理によって取得した256×256ピクセルの分割画像とした。よって、それらは1辺が約2.5km(1ピクセルは10m 四方)相当となる。この分割画像データの枚数構成を、分割画像内の地すべり移動体の割合(面積占有率)で正規化した。教師エリアの分割画像の総数を $Z$ 、各分割画像内の地すべり移動体の面積占有率の集合を $A$ 、その最大値を $a$ とすると、

$$a = \max A \quad \text{式1}$$

と表され、面積占有率の階級数を $N$ とすると、階級値 $X_i$ ( $i$ は階級番号)は、

$$X_i = \frac{a_i}{N} + \frac{a}{2N} \quad (i=1, 2, \dots, N) \quad \text{式2}$$

で求められる。地すべり地形のサイズの空間的不均一性による偏りを是正する正規化処理として、各階級の枚数 $Z_i$ は次のように確率 $P(X_i)$ の離散一様分布に従うものとした。

$$P(X_i) = \frac{1}{N}, \quad \text{式3}$$

$$Z_i = ZP(X_i). \quad \text{式4}$$

この正規化処理で、空間的不均一性からくる面積占有率ごとの枚数の偏りを是正することができる。今回は、最大面積占有率から4つの階級に分けることとし、各階級の分割画像からランダムに35枚ずつ(最大の階級に35枚しかなかったため)140枚選択した。この正規化処理をしたデータセットを表2のとおり「均等」と称す。均等の性能評価を行うために別途、「5%以上」「10%以上」「15%以上」の地すべり移動体の教師データセットを用意した。分割画像内の地すべり移動体の面積占有率5%未満、すなわち地すべり地形を含まない、または、極端に小さい分割画像は、予備実験でこれを多く含む(教師データの半分以上が面積占有率0%-5%)教師データにおいて不自然な出力結果となった。よって、学習の妨げとなる可能性があるとして、除外した。なお、20%以上のデータセットは、学習枚数が少なくなりすぎるため設けなかった。表2に示すように、教師データセットにおいて、均等が最も枚数が少ない。AIの教師データは、多ければ学習コストがかかるため、同等の性能を示すのならば少ない方が望ましい。よって、均等の性能評価が他データセッ

トと同等以上であれば、提案した正規化処理の有効性が示される。

### 5.2.2 空間的連続性を利用した検証データの作成と後処理方法

AIには一般的に不確実性（ノイズ・何を見ているかわからない）があるといわれているが、今回扱う地すべり地形の判読も、専門家によって結果が異なる（佐藤ら，2018）などの不確実性ははらんだテーマである。そこで、確からしさを上げるために、深層生成モデルからの出力に対して、今回提案する空間的連続性を利用した正規化を行った。

今回扱うデータは、空間情報の一種であり、空間的連続性を有す。よって、重複領域を含むように分割した検証データセットを複数作成し、推論処理後に重ね合わせ・抽出することで、出力結果を正規化して信頼性を向上させることが可能と考える。

図21（図の詳細は後述）は、検証データをスライドさせず分割（オリジナル）し推論を行い、その後、結合した推論画像（重複領域なし）である。この時、格子状の不自然な出力などが見受けられるが、これらが不確実性からくる偏りであると考えられる。これを、空間的連続性を利用して、正規化する手法を提案する。分割画像の縦・横のサイズを  $L_1, L_2$ 、分割する際の縦・横方向のスライドサイズを  $n, m$  としたとき

$$S_1 = \frac{L_1}{n} \quad (0 < n < L_1 | n \text{ は } L_1 \text{ の約数}), \quad \text{式 5 a}$$

$$S_2 = \frac{L_2}{m} \quad (0 < m < L_2 | m \text{ は } L_2 \text{ の約数}) \quad \text{式 5 b}$$

のように、その比は、重複領域を有する画像の枚数となる。よって、その積は、 $n, m$  のスライドサイズにより作成される同一重複領域を有する画像の総数となる。なお、本研究では、同一重複領域を有する画像で同一ピクセルでの地すべり移動体の出力数を「重なり量」と定義する。

重なり量の最大値  $o\_max$  はスライド割合  $S_1, S_2$  を用いて、

$$o\_max = S_1 S_2 \quad \text{式 6}$$

で計算される。ここで、不確実性を考慮するために  $o\_max$  からどれだけの範囲を許容するかを「ゆらぎ量」 $\sigma$  としたとき、許容する重なり量の最小値  $o\_min$  は

$$o\_min = o\_max - \sigma \quad \text{式 7}$$

となる。「ゆらぎ量」までを許容したパッチワイズの重なり量ごとの面積の集合を  $Q$ 、その要素を  $a_{j(k_n)}$ （箇所番号を  $j$  ( $j$  の最大値  $s$  は  $o\_min, o\_max$  によって決定される)、重なり量を数列  $k_n$ ) とすると

$$Q = \{a_{j(k_n)} | 1 \leq j \leq s(o\_min, o\_max), \{k_n\} = \{o\_min + n | n = 0, 1, \dots, \sigma\}, a_{j(o\_max)} \neq 0\} \quad \text{式 8}$$

となる。

図9に今回の処理手順の具体例を示す。その手順は、以下のとおりである。

1. 図9①のように、検証エリアからの切り出し位置をスライドさせることで分割位置をずらし、重複領域を有する分割画像を作成（ここでは4つのデータセット）する。
2. 各分割画像データセットを深層生成モデルに入力し推論結果を結合（図9②）する。
3. 結合した各データセットの推論結果を重ね合わせる（図9③）。これにより、画像内に出力頻度に応じた重なり量を有す領域ができる（ここでは0, 1, 2, 3, 4）。
4. 手順3で得た重ね合わせ画像の1パッチ（箇所）において各重なり量のパッチワイズ面積  $a_{j(k_n)}$  を要素とする集合  $Q$  ができ、さらに不確実性を考慮する式8の条件（ここでは、ゆらぎ量  $\sigma=2$ ）を適用することで図9④右上のような画像を得ることができる。

今回は、図9のように、分割画像サイズ  $L_1$  と  $L_2$  は256、スライドサイズ  $n$  と  $m$  は128とした。この時、出力結果と正解の画像全体を視覚的に判断したとき、ゆらぎ量  $\sigma=2$ 、として式8の条件で算出される箇所が結果として近しかった。このように、ゆらぎ量は、どこまでを正しい出力とするか不確実性を考慮するもので、専門家へ潜在的な地すべり地形候補地を明示する使い方を可能とする。

この処理では、スライドの大小・ゆらぎ量を任意で変更することができ、これらのパラメータの最適値は、対象エリアの地質・地すべりの分布状況などから決定される。よって、最適値の一般化には、多様な対象エリアでの適用結果を吟味する必要がある。一方で、推論結果と正解から再帰的に導いていく機械的な手法も考えられ、両者ともに今後の検討課題として挙げられ

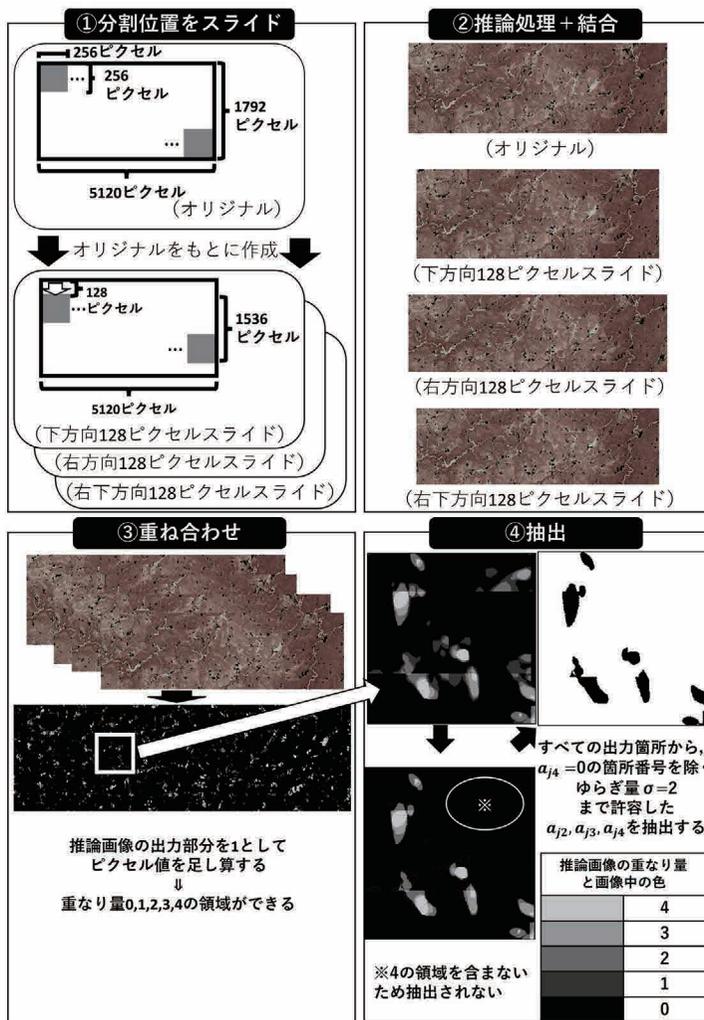


図9 検証データの作成と推論結果 (AI 出力) のとりまとめ

た。

以上の処理は、複数のフィルタをかけていることと同一視でき、残った部分の信頼性はオリジナルのみで推論をした場合よりも高くなっていると考えられる。また、同手法は、空間的連続性を有す他の地理空間情報への応用利用も期待できる。

### 5.3 性能評価方法

本研究では、学習を行った深層生成モデルの性能を評価するために、定量的評価を2種類と定性的・実務的視点の3つの方法で評価を行った。まず、定量的評価をするために機械学習の評価によく用いられる適合率・再現率と、推論画像が正解とどれだけ一致してい

るかを表す一致率を算出した。適合率は  $Pr$ 、再現率は  $Re$ 、一致率は  $Ma$ 、一致面積は  $TP$ 、誤判読面積は  $FP$ 、判読漏れ面積は  $FN$  とするとき、

$$Pr = \frac{TP}{TP + FP}, \quad \text{式9a}$$

$$Re = \frac{TP}{TP + FN}, \quad \text{式9b}$$

$$Ma = \frac{TP}{TP + FP + FN} \quad \text{式9c}$$

で求められる。ここで適合率とは、出力した場所が実際に正解であるものの割合を表す指標であり、再現率とは、実際に正解である場所に正しく出力できたものの割合を表す指標である。また、この評価方法ではピ

クセルワイズ（画素単位）で計算を行っている。適合率が高ければ、判読漏れ面積が少なく推論できていて、再現率が高ければ誤判読の面積が少ないといえる。次に、ピクセルワイズの視点よりも少しマクロな視点で評価するために地すべり移動体をバッチワイズ（箇所単位）で抽出率を計算した。ここで抽出率は、正解と出力が1ピクセルでも重なっている正解の箇所数を正解の地すべり箇所数で割った値である。この時、誤判読に当たる計算は、明らかに低い値になるため適合率計算の結果をもって省略した。抽出率は  $E$ 、正解と出力が重なった箇所数は  $tp$ 、正解の地すべり箇所数は  $Re$  とするとき、

$$E = \frac{tp}{Re} \quad \text{式10}$$

で計算される。

最後に、実務的な視点で出力が妥当なものかを確認するために、出力の大きさや一部を抽出した詳細について出力結果を精査した。

## 6. 結果・考察

### 6.1 提案した教師データの正規化処理の評価結果

教師データの面積占有率による正規化が、推論結果にどのような影響を与えているかを分割画像から評価した。図10～図15に、表2に示す枚数構成の教師データセットに対する推論結果の一部を示す。結果は、左からCS立体図・正解・5%以上・10%以上・15%以上・均等の順に並んでいる。なお、推論結果は、地すべり移動体の有無で2色（黒：有、白：無）で出力するようにしているが、ここではCS立体図上に地すべり移動体の出力のみを重ね合わせている。

また、定量評価として、ピクセルワイズとバッチワイズでのAI性能評価及び地すべり移動体の出力箇所の大きさ分布評価を行った。

#### 6.1.1 教師データの面積占有率による正規化処理の効果（定性評価）

均等の結果は、図10～図15を見ていくと、5%以上と同等な大ききで出力したり、15%以上と同等な大ききで出力したりと、出力のフレキシブルさが推察される。これは、均等では学習した面積占有率に偏りがなかったため、フレキシブルな出力が可能な深層生成モデルのパラメータの重み付けがされたためと考えられる。

る。

また、面積占有率が高い教師データだけを学習させた場合ほど、サイズが大きい地すべり移動体を出力する傾向にある。これは、深層生成モデルが、与えられた教師データと同程度のサイズに近づくように学習されたモデルパラメータを有するためであると考えられる。

図10（上）では、5%以上の場合に出力しきれていない地すべり移動体が、面積占有率の高いデータで学習した10%以上・15%以上、または、均等では学習枚数が少ないにも関わらず、すべて出力されている。一方で、図10（下）は、5%以上では比較的妥当な推論結果だが、学習する面積占有率が大きくなるごとに山の裾の緩斜面に出力していて、過剰抽出が大きくなっている。これは、上述のとおり、与えられた教師データと同等の面積に近づけるように出力しようとするため起こる特徴である。逆に言えば、対象とするエリアの地すべりのサイズによって、学習させる面積占有率を変更することで、出力をコントロールすることが可能ということである。また、均等では、対象とするエリアの地すべりの大ききにかかわらずフレキシブルな出力性能を有していることが推察される。

#### 6.1.2 正解に近い出力が見られる例（定性評価）

図11は、正解に近い出力が見られる画像の一部である。また、図12では、少なくとも正解に重なるような位置に出力している。これは、過去に地すべりがあったが、時間の経過で開析して地すべり地形の特徴が薄れてしまい、出力地点にしか残っておらず、正解よりも小さな出力になったと考えられる。

先行研究（古木ら、2019）（古木、2021）でも、出力の特徴は急斜面-緩斜面（濃色から赤の線を隔てた淡色領域）の位置に存在する緩斜面を認識していて、判読しづらい（開析している）箇所については正しく出力する能力が低下するといった点で同様な出力傾向が見られている。

#### 6.1.3 過剰抽出・判読漏れの例（定性評価）

教師データの面積占有率による正規化が、過剰抽出・判読漏れにどのような影響を与えているかを分割画像の推論結果から評価した。

図13では、CS立体図の淡色領域に反応して出力している。この学習において地すべり移動体の出力は、

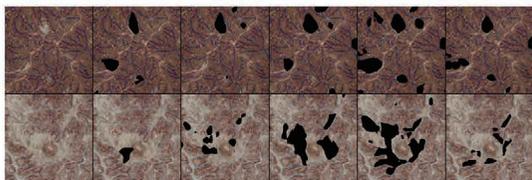


図10 学習した面積占有率で異なる出力結果例

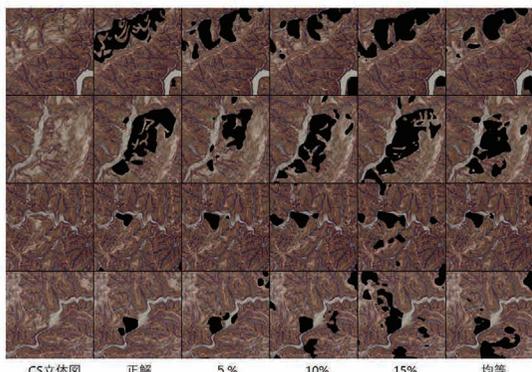


図11 正解に近い出力例

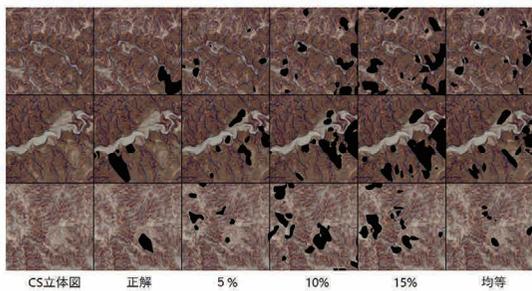


図12 正解の位置に小さい出力がある例

特に急斜面-緩斜面に注目していると考えられる。そのため、地すべり地形がCS立体図内に無い場合、単に急斜面-緩斜面であるだけの位置でも、地すべり移動体がある画像のみで学習したため、地すべり地形と誤判読し、緩斜面に出力しているものと推察される。これは、先行研究(古木ら, 2019)(古木, 2021)でも同様な出力があり、CS立体図上での地すべり地形と色調が類似した、地すべり地形ではない急斜面緩斜面の特徴を有す緩斜面に出力されたものと推察される。よって、教師データ内に少数でも地すべり地形がない画像(防災科研の正解データだけでなく、どの判読技術者が見ても地すべり地形のないCS立体図)を少量混ぜることで推論結果に過剰な出力をしなくなる可能性があると考えられる。

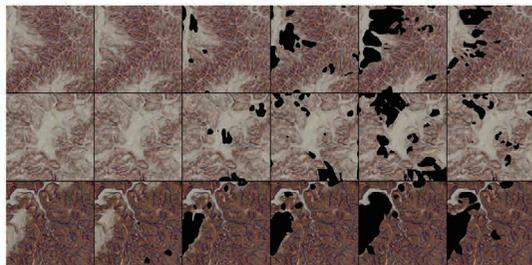


図13 緩斜面(淡色)に反応した出力例

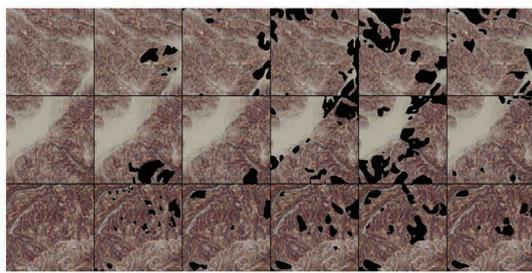


図14 判読漏れ例

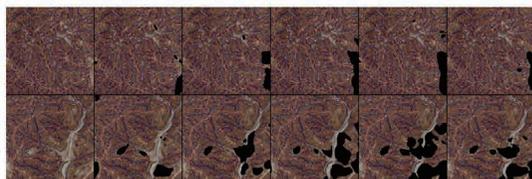


図15 同一地すべりで分割画像毎に出力が異なる例(上-西, 下-東で連担している)

図14(上2枚)では、大きめの地すべり移動体を判読漏れしている。しかし、このいずれの地すべり地形も、人力(専門家)での判読をする場合に意見が分かれそうな地点であり、この分割画像では、他の箇所の方を地すべりとして優先して出力したいエリアと推察される。この時、防災的な安全性を考慮して正解の位置に出力させるならば、面積占有率の大きなデータで学習した結果を使うことが望ましい。このように、面積占有率による正規化処理は、出力のコントロールも可能な長所を有している。

図14(下)のように、小規模で多数の地すべり移動体がある分割画像では、10mメッシュのデータでは特徴を拾いきれず、正しく出力できていない可能性がある。しかし、周辺には出力されており、専門家への「地

すべり候補地」としては、この出力状態でも有用であると考えられる。一方で、メッシュの分解能を高くすれば、精度向上の可能性は考えられるが、情報量は多く、学習コストが高くなる可能性があり、最適な DEM サイズについては、詳細な検討が必要と考える。

全体的には、過剰抽出が多い結果が得られた。しかしながら、防災科研の正解にはないが、CS 立体図から判読すると地すべり地形と考えられる場所や沖積錐、採石場に出力している箇所が少なからず存在する。いずれの場合も、災害につながる（土砂移動が起きやすい・起きている）可能性がある地形で、防災面から考えるとこれらの出力は、意義のある結果と考える。

#### 6.1.4 AI 性能評価（定量評価：ピクセルワイズ）

ピクセルワイズの性能評価結果は、表 3 のように適合率・再現率・一致率を算出した。学習する面積率を上げると再現率が増加し、適合率が減少することから、

表 3 出力結果の正規化処理前・後の一致率・再現率・適合率計算結果（ピクセルワイズ）

	教師データセット	再現率	適合率	一致率
正規化処理前	5%以上	42%	11%	10%
	10%以上	51%	6%	6%
	15%以上	62%	4%	4%
	均等	43%	8%	7%
正規化処理後	5%以上	39%	14%	11%
	10%以上	51%	7%	6%
	15%以上	65%	5%	5%
	均等	42%	11%	10%

学習する面積率を上げていけば「正解の地すべり地形箇所に出力する」能力は上がるが、「正解の非地すべり地形に出力しない」能力は低下する傾向にあることがわかる。

また、先行研究（古木，2021）と比較して一致率が低い結果となった。これは、今回、誤判読面積が多めな結果となり、適合率を低下させているためと推察される。ピクセルワイズの性能評価結果については、先行研究（古木，2021）でも述べられている通り、およそその位置に出力はされているが、大きく出力したり、小さく出力したりして、適合率・再現率を低下させていることから、地すべり移動体の「形状」を再現することは困難であることを示している。

#### 6.1.5 AI 性能評価（定量評価：パッチワイズ）

表 4 にパッチワイズの性能評価を示す。この結果から、抽出率は出力結果の正規化前の方が 6～7 割と高く、正規化後の 4～7 割の抽出率より良い結果となった。先行研究（古木，2021）の出力結果と比較すると、同等以上の結果を示している。しかしこれは、AI 出力箇所総数・過剰抽出を見ると出力結果の正規化前では、先行研究と比較しても、かなり多くの箇所を出力している。したがって、不確実性に起因する過剰抽出が多くなっている。すなわち、でたらめに多く出力した結果、正解箇所に出力しているだけの状態である。なお、詳細は後述するが、出力結果の正規化後では、大幅な出力箇所（過剰抽出）の削減がなされていて、且つ、正解率は大幅には落ちていないことから、出力結果の正規化（フィルタリング）が有効に働いているものと考えられる。

表 4 出力結果の正規化処理前・後の評価結果（パッチワイズ）

	教師データセット	正解の移動体総数	AI 出力箇所と重なる正解の移動体総数	過剰抽出	AI 出力箇所総数	抽出率
正規化処理前	5%以上	186	106	854	954	57%
	10%以上	186	113	1518	1619	61%
	15%以上	186	131	1900	1990	70%
	均等	186	111	1448	1550	60%
正規化処理後	5%以上	167	61	207	259	37%
	10%以上	167	88	318	381	53%
	15%	167	116	409	471	69%
	均等	167	71	302	358	43%

### 6.1.6 地すべり移動体の出力箇所大きさ分布評価 (定量評価)

図16～図20にパッチワイズ面積のヒストグラム、図21（上から5%以上・10%以上・15%以上・均等・正解）に検証エリアをすべて結合した結果（出力結果の正規化処理前）を示す。

図16～図20のヒストグラムをそれぞれ比較すると、15%以上、10%以上では出力面積が明らかに大きく、5%以上、均等ではおおよそ正解の分布と似た結果となった。上述の定量評価では15%以上の教師データセットがより良い判定であったが、これは、ここでの結果で見られるように面積占有率が大きい画像のみで学習させると、出力箇所が大きくなり、その結果、正解部分を含んでしまうことが理由としてあげられる。専門家が利用する一次資料での地すべり候補となるためには、たとえ正解の位置に出力していても、明らかに地形の様相に対して不自然な広い範囲を出力することは好ましくない。これに対して、均等では、正解の地すべりの大きさに応じてフレキシブルに出力されている。これは、深層生成モデルが学習した地すべり移動体の面積占有率に偏りがなかったために、フレキシブルな出力が可能なモデルパラメータの重み付けがされたためと考えられる。

## 6.2 出力結果の正規化処理評価

出力結果の正規化の有効性をヒストグラム、結合した画像から評価した。

### 6.2.1 空間的不均一性と空間的連続性の補完関係

図15（上下）は、一塊の地すべり移動体上に分割位置が設定され作成された検証データからの推論結果である。よって、図15（上）右辺と図15（下）左辺はもともと連担している（接している）。図15（上）分割画像内右下の地すべり移動体と図15（下）分割画像内左下の地すべり移動体は同一の地すべり移動体で分割されたものであるが、図15（上）では出力され、図15（下）では出力されていない。これは、AIが地すべりにおける側方の谷（CS立体図上では青色の線）を特徴としてとらえていると考えられ、図15（上）には青色の線がはっきりとCS立体図にあるが、図15（下）には見切れている。そのためこのように同一の地すべりでも、画像の分割位置次第で、AIの不確実性による差異が生まれると推測される。このような現象に対して、出力結

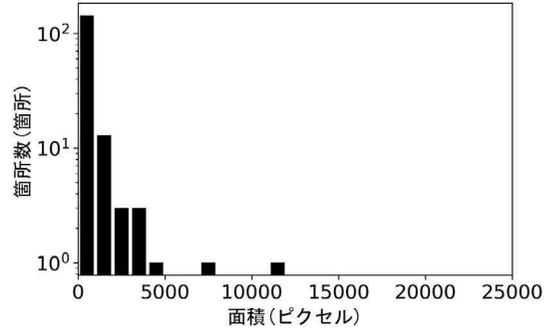


図16 地すべり移動体のパッチワイズ面積ヒストグラム (正解)

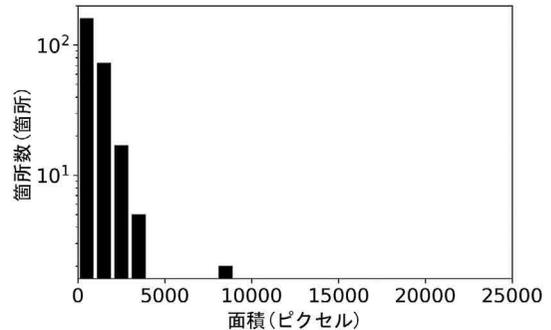


図17 地すべり移動体のパッチワイズ面積ヒストグラム (5%以上)

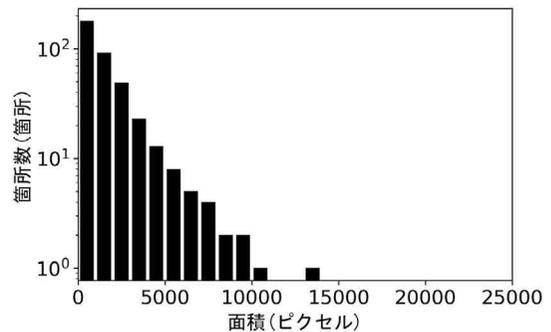


図18 地すべり移動体のパッチワイズ面積ヒストグラム (10%以上)

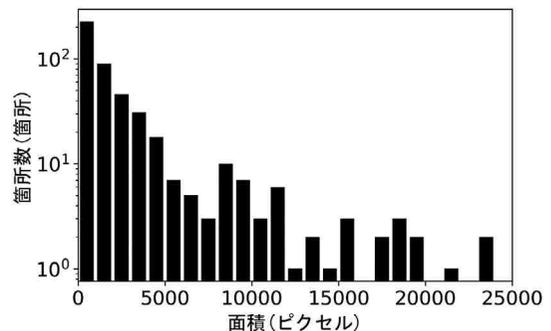


図19 地すべり移動体のパッチワイズ面積ヒストグラム (15%以上)

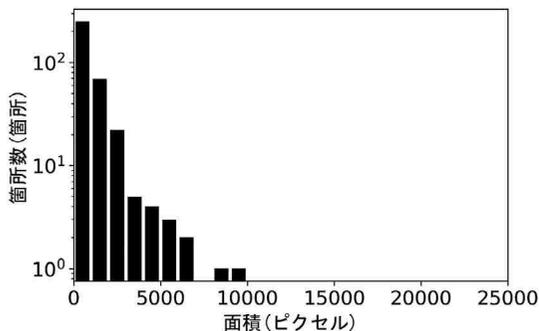


図20 地すべり移動体のパッチワイズ面積ヒストグラム (均等)

果の正規化は、適切な出力をもたらすものと考えられる。

### 6.2.2 出力結果の正規化処理前の検証エリア全体の評価

図21に正規化処理前のエリア全体の画像を示す。図21（上から5%以上・10%以上・15%以上・均等・正解）を比較すると、正解画像では東側に地すべり移動体が多く存在するが、出力結果の正規化前では、検証エリア全体に出力されている。さらに、分割画像周縁部分の不自然な接合の格子状の出力が現れている。また、10%以上・15%以上の結合結果やヒストグラムからもわかる通り、正解では5,000ピクセル以下の地すべり移動体がほとんどない中、10%以上・15%以上では5,000ピクセル以上の出力が多く、明らかに出力される面積が大きい。そのため、専門家からすると、明らかに土砂移動がない場所を出力箇所（候補地）から外すといった手間を要求される。その点で、5%以上および均等では、出力面積が小さく、正解をカバーできず正解率は低かったが、出力の周辺には土砂移動に関わる場所が多くあり、逆に、出力がない場所には高い確率で何もないため、専門家に示す一次資料の精度向上において有用性があるものとする。

面積占有率による正規化を施した均等は、最も学習枚数の多い5%以上の教師データセットの1/8程度の教師データ枚数で学習しているにもかかわらず、5%以上と同等の結果を出すことができています。また、本研究のマシンスペック(5.1に記載)において、5%以上の学習時間が24時間以上だったことに対して、学習枚数が少ない均等のデータセットでは約6時間程度となり、学習時間が1/4程度に短縮された。このこと

から、地すべりの深層生成において面積占有率による教師データの正規化の有用性が示された。また、均等では5%以上よりも大きく出力している場合もあるが、これは大きめの地すべり移動体に対してフレキシブル（大きいものは大きく、小さいものは小さく）に出力した結果と推察される。

### 6.2.3 出力結果の正規化処理後の検証エリア全体の評価

図22に正規化処理後のエリア全体の画像を示す。図22（上から5%以上・10%以上・15%以上・均等・正解）に正規化処理後の出力結果を示す。正規化処理前の出力結果と比較して、格子状の出力は目立たなくなり、明らかに地すべり地形の無い領域の出力をキャンセルできている。これは、深層生成モデルの特性上、何かしら出力してしまう課題に対して、正規化が適切な処理を施したものと考えられる。また、面積の小さい出力が目立つが、これは、先行研究(古木, 2021)では正規化処理で是正された、画像を分割した際の見切れてしまった地すべり移動体を学習していることや、開析が進んでいて移動土塊の特徴が薄れてきた箇所であることが原因として考えられる。

### 6.3 誤判読・判読漏れ箇所の検証

より詳細に検証を行うため図23～図26のように、地すべり移動体の多い検証エリアの東側と少ない西側で、均等および5%以上において1,000×1,000ピクセルの範囲を無作為的に設定し、空中写真・地形図・現地調査による検証を行った。10%以上・15%以上は、上述のとおり、明らかに過剰抽出が多いため、検証対象から除外した。

図23～図26中の記号は次のことを示している。

- ・赤円-地すべり地形または沖積錐などの土砂移動があると思われる
- ・黒円-正解に地すべり地形がある
- ・黄四角-土砂移動がないと思われる
- ・青三角-正解には地すべり移動体があるが出力していない

図23・図24に示す西側のエリアでは、地すべり移動体は少ないが、深層生成からはある程度出力された。さらに、そのほとんどで土砂移動が起きている箇所と判読された（地すべりと沖積錐ないしその他は半々くらい）。土砂移動が起きていないと判読される箇所は

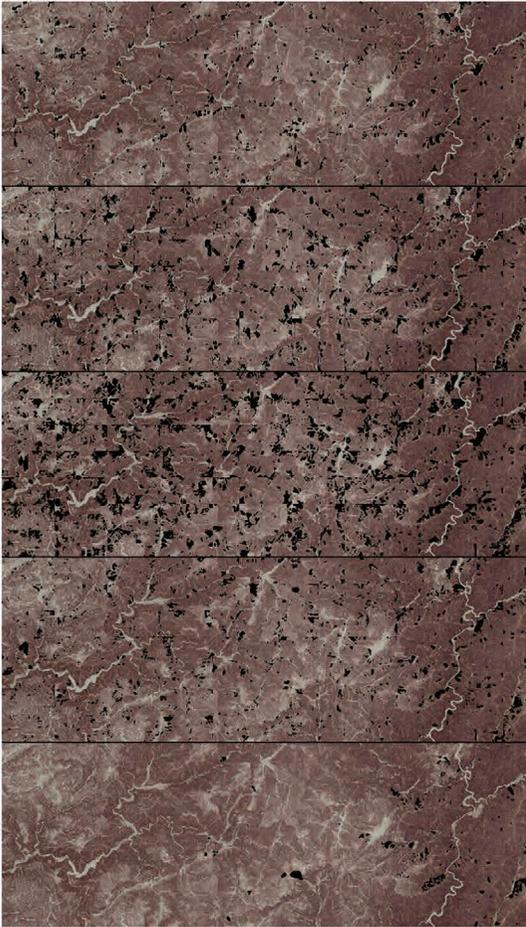


図21 出力結果の正規化処理前（上から5%以上・10%以上・15%以上・均等・正解）

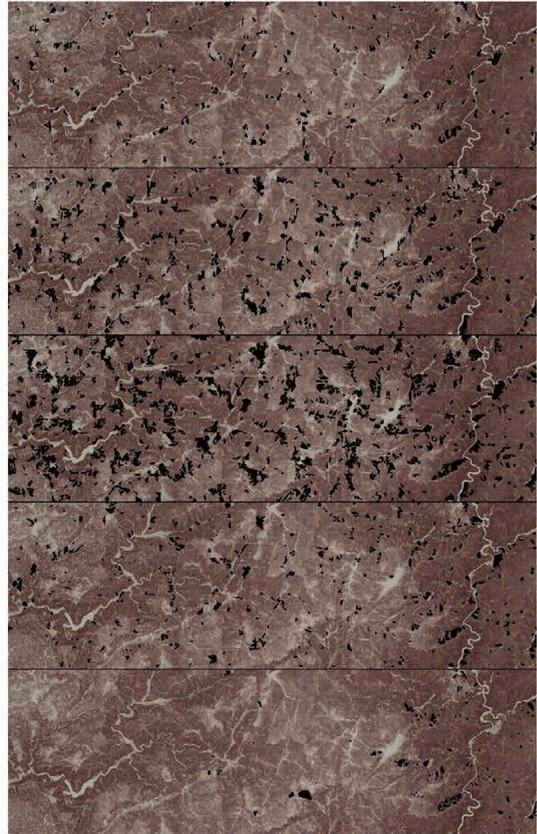


図22 出力結果の正規化処理後（上から5%以上・10%以上・15%以上・均等・正解）

あったが、この範囲内では8割以上が土砂移動に関わる箇所と判読される。さらに土砂移動がないとしている黄四角の箇所は、土地が改変されたと思われるゴルフ場と山頂付近が風化して平坦になったと判読される場所である。このような場所では、出力の位置よりも、その周辺で表層崩壊が起きる可能性がある。

図25・図26に示す東側エリアは、地すべり移動体の多い地域であるが、その5割を出力した結果となっている。さらに過剰抽出となっている箇所も沖積錐などの土砂移動があると思われる位置に出力しており、これを含めると約7割が土砂移動に関する箇所となり、先行研究(古木, 2021)と比較しても同等な結果となった。ここで判読漏れになっている箇所は、もともと地すべり移動体の面積自体が小さい箇所、もしくは、地すべり発生後時間が経過して地すべりの特徴を呈して

いないもので、専門家でも判読することが難しい箇所と推察した。しかし、ピンポイントで出力されていなくても、地すべり移動体周辺に出力が見られる場所があった。これは、地すべり地形は地盤の弱いエリアでよく発生するといった特徴から、注視したいエリアの“あたり”をつけるという点で、専門家の判読支援につながるものとする。よって、このように防災科研のデータでは地すべり移動体と判読されてなかった箇所でも、防災に大きく関わる主題図を作成する潜在的な目的においては、不正解という位置づけとはならない箇所が出力されていた。以上より、提案する正規化手法は、後に専門家の判断を仰ぐ、地すべり移動体に関連する土砂移動の候補地の情報提供としての位置づけならば、有用な推論結果を出力する性能を高めるものとする。

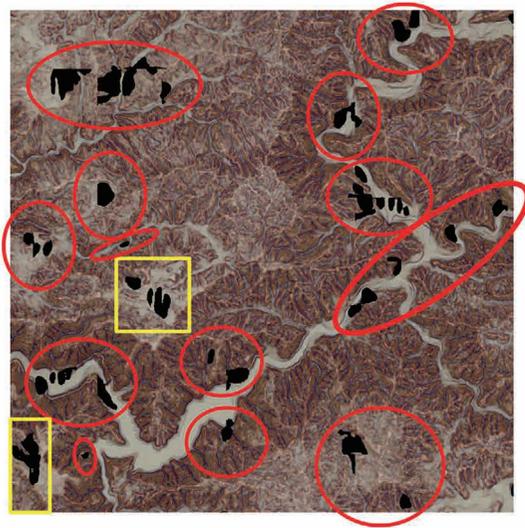


図23 5%以上の検証結果（西側）

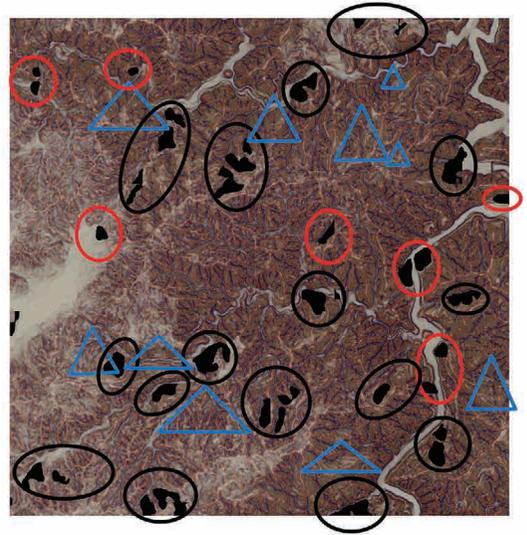


図25 5%以上の検証結果（東側）

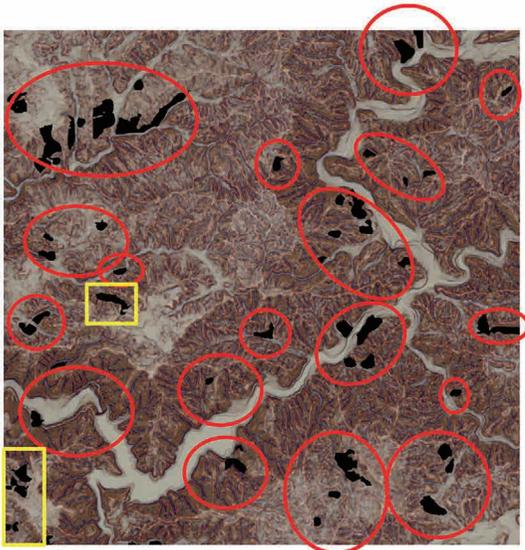


図24 均等の検証結果（西側）

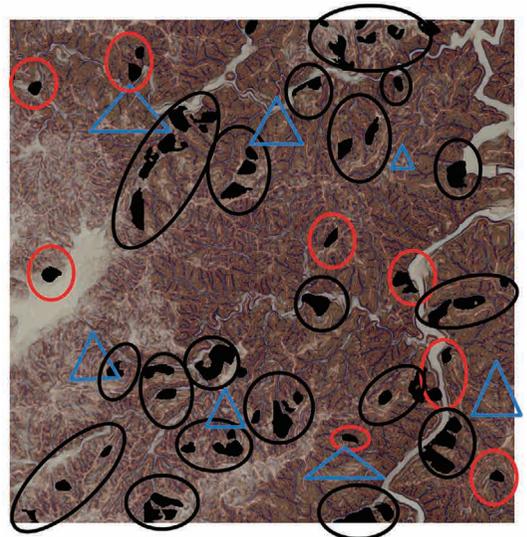


図26 均等の検証結果（東側）

## 7. 総合考察

本研究では、教師データの選定の方法として、同じ大きさに切り出した地すべり地形分布図のうち地すべりの面積占有率が5%以上・10%以上・15%以上、および、正規化手法による、均等の4通りで学習させた。定量評価では、教師データとして与える画像の面積占

有率が大きいほど、よく地すべり地形を抽出できる（その分過剰抽出も多い）といった結果となった。正規化手法を施した均等は、地すべり地形のサイズに応じたフレキシブルな出力が確認できた。また、空間的連続性を利用し、出力結果の正規化処理を行った。結果としては、分割画像周縁部分で見られた不自然な接合の格子状の出力などの不確実性を低減し、信頼性の高い出力を可能とした。

## 7.1 空間的不均一性と面積占有率による教師データの正規化効果

面積占有率による正規化を施した「均等」での学習を行った結果では、最も少ない学習枚数(140枚)であるにもかかわらず、学習枚数の多い5%以上(1069枚)と同等の結果を示した。視覚的には、5%以上が最も良い出力に見えるが、これは地域的に地すべりの面積が大きくないために適切な学習がなされたのではないかと考えられる。この結果から、面積占有率で正規化した教師データセットで学習を行った方が効率的な学習が可能であると推察される。すなわち、学習データの作成面からみても効率的であり、コスト低減を可能とする手法であると考えられる。さらに、「均等」は、出力面積のフレキシブルさを有し、地すべりの面積がさらに大きなエリアにも対応できる可能性があり、今後様々なエリアで検証する予定である。

本研究では、ゆらぎ量を含ませた出力を最終結果とした。その中には地すべりではなくても土砂移動と思われる箇所が多くあった。これは、防災の観点から専門家に渡す一次候補地として有用性のある出力と考える。

## 7.2 空間的連続性を利用した出力結果の正規化効果

本研究では、最大重なり量  $o\_max=4$ 、ゆらぎ量  $\sigma=2$  で処理を行ったが、スライドサイズ  $n, m$ 、分割画像サイズ  $L_1, L_2$  を変更することで  $o\_max$  を自由に決定できる。この時  $o\_max$  を大きくすることでフィルタの数が増えて、精度も向上していくのではないかと考えられるが、ゆらぎ量のレンジも広くなることで最適値が定めづらく、精度と手間のトレードオフとなる箇所もあるので、今後の検討課題の一つである。また、本手法は空間的連続性を有す地理空間情報にも適用可能と考えられ、創造性を有すものとする。

## 7.3 地質との関わり

今回の対象エリアは主に花崗岩質と泥質片岩が存在する場所で、一様な地質分布ではなかった。そして、概ね泥質片岩のエリアに地すべり地形が分布していた。地すべりのサイズ等は地質に関わるところも大きいため、他の地質域での正規化処理の設定パラメータの最適範囲の検証などが今後の検討課題として挙げられた。

## 7.4 深層モデルの性能向上

定量評価結果においては、一般的な深層生成より低い結果が得られた。これを改善するためには、ベースとする深層生成モデルの検討や地質情報を利用して条件付きの生成を行うことが考えられる。しかしながら、これらの手法を利用するにあたっては、今回提案した2つの正規化処理手法は有効なものとする。

## 8. 結 論

本研究は、地すべり地形の空間的不均一性による教師データの偏りを、地すべり移動体のサイズで正規化し、学習した深層生成モデルの性能評価と検証データの空間的連続性を活用した出力の正規化の有効性評価を行った結果、以下のことが明らかとなった。

1. 面積占有率で正規化(データの枚数構成)した教師データセットは、枚数は少なくとも、大量の不均一な教師データと同等の性能が得られた。
2. 空間的連続性を利用した出力結果の正規化は、不自然な出力を低減し、信頼性の高い出力を可能とした。これは、同様に空間的連続性を有す様々な地理空間情報に適用可能と考えられ、創造性を有すものと考えられる。

以上のことから、本研究の提案する正規化手法は、空間情報系の深層生成において、有効であることを明らかにした。また、これらによる出力は、専門家が活用する一次資料として活用できる有用性を確認した。

(受付日2021.11.10, 受理日2022.2.14)

## 参考文献

- 荒木光一, 2019. AIによるDEMからの地すべり地形抽出技術. 2019年度日本地すべり学会シンポジウム講演集, 23-26.
- 大八木規夫, 内山庄一郎, 小倉 理, 2015. 地すべり地形分布図第60集「関東中央部」地すべり地形分布図の作成方法と活用の手引き. 防災科学技術研究所研究資料, 第394号, 1-14.
- 岡谷貴之, 2019. 機械学習プロフェッショナルシリーズ深層学習. 講談社, 東京, 第21刷, 33-35.
- 佐藤 剛, 土志田正二, 2018. 地すべり地形分布図を作成するうえで地形判読の専門家は地すべり地の何を見ているのか?. 公益財団法人国土地理協会第18回学術研究助成, <https://www.kokudo.or.jp/grant/>

- pdf/2018/sato206.pdf. (2021/11/ 8 確認)
- 産総研地質調査総合センター. 地質図 Navi. <https://gbank.gsj.jp/geonavi/geonavi.php#10,35.04874,137.50585>. (2021/11/ 8 確認)
- 戸田堅一郎, 2014. 曲率と傾斜による立体図法(CS 立体図)を用いた地形判読. 森林立地, Vol. 56, No. 2, 75-79.
- 長野県. 数値地形データを用いた「微地形図」の作成方法. <https://www.pref.nagano.lg.jp/ringyosogo/seika/documents/bichikei.pdf>. (2021/11/ 8 確認)
- 野呂智之, 神山嬢子, 鈴木大和, 戸館 光, 中西宏彰, 家田泰弘, 片嶋啓介, 大坪隆三, 相澤明宏, 塩見礼也, 2018. 深層学習を用いた画像解析及びクラスタリングによる土砂災害の素因特性の抽出. 第67回平成30年度砂防学会研究発表会概要集, 667-668.
- 古木宏和, 稲垣 裕, 一言正之, 藤平 大, 櫻本智美, 2019. ディープラーニングによる地すべり地形の自動抽出: 精度と教師データの関係 (特集 AI とビッグデータ). 地盤工学会誌, Vol. 67, No. 6, 20-23.
- 古木宏和, 2021. 3次元地形情報を用いた深層学習による地すべり移動体抽出—学習データに用いる地形図と抽出精度の関係—. 日本地すべり学会誌, Vol. 58, No. 2, 65-72.
- 防災科学技術研究所, 2002. 地すべり地形 GIS データ: 国立研究開発法人防災科学技術研究所地すべり地形分布図. [https://dil-opac.bosai.go.jp/publication/nied\\_tech\\_note/landslidemap/gis.html](https://dil-opac.bosai.go.jp/publication/nied_tech_note/landslidemap/gis.html). (2021/11/ 8 確認)
- 光谷和剛, 山本佳士, 園田 潤, 木本智幸, 2021. レーザ画像および GAN を用いたコンクリート内部欠陥の位置・寸法情報の可視化に関する基礎的検討. 日本計算工学会論文集, 2021巻, 1号.
- Hendrycks, D., Zhao, K., Basart, S., Steinhardt, J. and Song, D., 2021. Natural Adversarial Examples. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 15257-15266.
- Isola, P., Zhu, J.-Y., Zhou, T., and Efros, A.A., 2017. Image-to-Image Translation with Conditional Adversarial Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 5967-5976.
- Krizhevsky, A., 2009. Learning multiple layers of features from tiny images. <https://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf>. (2021/11/ 8 確認)