Pix2pixを用いた急傾斜地崩壊危険箇所の推定

西 結人^{1,a)} 重井 徳貴^{1,b)}

概要:がけ崩れのハザードマップに利用される情報である急傾斜地崩壊危険箇所などの調査は、専門家な どの人手で行われており、労力と時間を要する.これに対し、深層学習の画像生成モデルである pix2pix を用いて土地起伏図からリスク地形を推定することが試みられている.本研究では、急傾斜地崩壊の危険 箇所の推定に pix2pix を用いる際の効果的な手法について検討する.入力画像に起伏図や空中写真に加え て標高タイルを用いる手法や、過学習対策としての正則化適用、危険箇所の見逃しを無くすための損失関 数を提案する.複数の条件で数値実験を行い、提案手法の有効性を検証する.

Estimation Methods of Slope Failure Hazard Areas by Using Pix2pix

Abstract: Surveys of slope failure hazard areas used in landslide hazard maps are conducted manually by experts and are labor- and time-consuming. This study investigates effective methods using pix2pix to estimate slope failure hazard areas. Our proposals are using elevation tiles as input images in addition to elevation maps and aerial photographs, regularization to prevent over-learning, and a loss function to eliminate missed hazard points. Numerical experiments are conducted under several conditions to verify the effectiveness of the proposed methods.

1. はじめに

山地が6割を占める日本では、台風・地震・大雨が多い ことから急傾斜地崩壊(がけ崩れ)などの土砂災害が多発 している.防災のために、行政は急傾斜地崩壊において危 険性がある場所を急傾斜地崩壊危険箇所や土砂災害警戒区 域として公表しているが、この調査は専門家などの人手で 行われており、労力と時間を要する. これに対し、深層学習 のモデルの一つである pix2pix を用いて土地起伏図からリ スク地形を推定することが検討されている [1], [2], [3]. 文 献 [1] においては, 赤色立体地図 [4] を入力画像として用い て大規模崩壊に関連する地形を推定することが試みられて おり、技術者による判別が容易な地形に関してはある程度 の推定が可能であることが示されている. 文献 [2], [3] では 地すべり地形の推定が試みられており、入力画像について CS 立体地図に地質図を加えた方が良いこと [2], 等高線図 よりも CS 立体図の方が効果的であること [3] が示されて いる.これらが使用する画像は赤色立体地図 [4] や CS 立 体地図 [5] などの土地起伏図や地質図などであるが, 急傾斜 地崩壊のリスク地形は, 家屋の有無も考慮する必要がある. これに対し, 畳み込みニューラルネットワークを用い, 空中 写真により家屋の有無を考慮して急傾斜地崩壊危険箇所を 推定する手法が検討されている [6]. しかしながら, 発展的 な深層学習のモデルである pix2pix を用いた急傾斜地崩壊 のリスク地形の推定についての検討は行われていない.

本研究では、急傾斜地崩壊の危険箇所の推定にpix2pix を用いる際の効果的な手法について検討する.pix2pix は 画像生成モデルの1つであり、画像変換タスクを担う.汎 用性が高く、白黒画像からのカラー画像の生成、航空写真か らの地図画像の生成、風景写真からの夜の風景写真の生成 など様々な変換例がある.本研究の提案手法では、空中写 真と土地起伏図である赤色立体地図に加え、標高タイルを 入力画像として、土砂災害の危険箇所の推定を行う.さら に、過学習対策としての正則化適用や、リスク地形の見逃し を無くすために再現率を重視する損失関数を提案する.急 傾斜地崩壊危険箇所に加えて、より正確な危険箇所の情報 であると考えられる土砂災害警戒区域について複数の条件 で数値実験を行い、効果的な手法について検討する.

鹿児島大学 Kagoshima University, Kagoshima, Kagoshima 890–0065, Japan

^{a)} k3220082@kadai.jp

^{b)} shigei@eee.kagoshima-u.ac.jp



図 1 線画を写真に変換する cGAN の概要 (出典: 文献 [3] の Figure 2)

2. Pix2pix

2.1 GAN

GAN (Generative Adversarial Networks: 敵対的生成 ネットワーク)は生成モデルで生成器と識別器の2つの ネットワークが敵対的に学習を行い,学習データに類似す るデータを生成するネットワークである[7].生成器はラン ダムノイズを入力として正解データらしいデータを生成し, 識別器は正解データであるか生成データであるかを識別す る.敵対的な学習では,生成器は生成のクオリティを上げ て識別器に識別されないように学習し,識別器は誤識別し ないように学習する.より精度の高い敵と競い合って学習 することで互いの精度を高めていくような学習を行う.

2.2 Pix2pix

GAN において生成器ではランダムノイズを元に正解デー タらしいデータを生成するため、生成データをカテゴリなど 特定の条件でコントロールすることはできない.そこでラ ンダムノイズに加え条件の情報を入力することで、特定の条 件のデータの生成を可能にしたものが cGAN (conditional GAN:条件付き GAN)である.pix2pix はこの cGAN の一 種で、汎用的な画像変換タスクを担う [8].図1に示すよう に、生成器 G は入力画像 (変換元画像) x を入力として正解 画像 (変換先画像) y に近い画像を生成する.識別器 D は 入力が生成画像 G(x) と入力画像 x のペアであるかを識別する.

2.2.1 ネットワークの構成

生成器には U-Net が用いられる. U-Net は Encoder 部 と Decoder 部で構成された Encoder-decoder ネットワーク にスキップコネクションを追加したネットワークである. Encoder では畳み込みによりダウンサンプリングしながら 入力画像から特徴を抽出し, Decoder では逆畳み込みによ りアップサンプリングしながら特徴マップから画像を復元 する.スキップコネクションでは, Encoder の各層で出力 される特徴を Decoder のサイズの対応する各層と共有す る.これにより, 逆畳み込み時に入力される特徴量が増え, 生成精度の向上が期待できる.

識別器には PatchGAN と呼ばれる手法を用いる. この手 法は図2に示すように画像全体をパッチに分割し, パッチ 単位で本物ペア・偽物ペアを判別するもので, 画像のディ

図 2 GAN における識別器の出力

テールについての妥当性が得られる.ネットワークは畳み 込み層のみで構成される畳み込みニューラルネットワーク であり,入力は画像全体で,出力はバッチの判定結果から構 成される特徴マップである.出力の特徴マップの1ピクセ ルは入力画像のある領域 (receptive field)の影響を受けた 値となるので, receptive field とパッチのサイズが一致する ようにネットワークの設計を行うように実装されることが 多い.

2.2.2 損失関数

学習に用いられる損失関数は従来モデルでは,識別器は 式 (1),生成器は式 (2)が用いられる. $L_{advD} \geq L_{advG}$ は識 別器と生成器の敵対的な学習についてのロスであり,それ ぞれ式 (3) と式 (4) で表わされる. L_{L1} は L1 ノルム損失で 式 (5) で表される.

$$L_D = L_{advD} \tag{1}$$

$$L_G = L_{advG} + \lambda \cdot L_{L1} \tag{2}$$

$$L_{advD} = E_{x,y}[-\log D(x,y)] + E_x[-\log(1 - D(x,G(x)))]$$
(3)

$$L_{advG} = E_x[-\log(D(x, G(x)))] \tag{4}$$

$$L_{L1} = E_{x,y} \left[||y - G(x)||_1 \right] = \sum_{i=1}^{i=N} |\gamma_i - G(x)_i| \quad (5)$$

ここで、 λ は重み、Gは生成器の出力である生成画像、Dは 識別器の出力の本物ペアである確率、xは入力画像、yは正 解画像、zはノイズ、Nは画像の画素数、 E_x [·]は入力xに 対する期待値、 $E_{x,y}$ [·]は入力xと正解画像yに対する期待 値、 $||\cdot||_1$ はL1ノルムであり差の絶対値の和を表す、学習 では、生成器と識別器の畳み込み処理で用いられるフィル タの重みパラメータそれぞれについて、損失関数の偏微分 を計算し、損失関数を最小化するように重みパラメータの 更新を行う.

Pix2pix を用いた急傾斜地崩壊のリスク地 形の推定

3.1 急傾斜地崩壊危険箇所

国土交通省は,がけ崩れの防災として急傾斜地崩壊危険 箇所に関する調査を実施し公表している [9].急傾斜地崩壊 危険箇所は急傾斜地及びその周囲で人家等への被害が想定



図 3 急傾斜地崩壊危険箇所(出典:福岡県提供資料により作成した 国土数値情報)

される箇所で,急傾斜地は「傾斜度30度以上かつ高さ5m 以上の土地」である.福岡県提供資料より作成した国土数 値情報の急傾斜地崩壊危険箇所の例を図3に示す.色が付 いている箇所が急傾斜地崩壊危険箇所と指定されている.

3.2 土砂災害警戒区域

急傾斜地崩壊の土砂災害警戒区域は,急傾斜地の崩壊が 発生した場合に、住民の生命または身体に危害が生ずるお それがあると認められる区域で,平成13年4月1日に施行 された「土砂災害警戒区域等における土砂災害対策の推進 に関する法律」に基づき指定されている[10]. 地形的基準 は,3.1節の急傾斜地崩壊危険箇所と同様に「傾斜度30度 以上かつ高さ5m以上」となっている.

3.3 急傾斜地崩壊危険箇所と土砂災害警戒区域の違い

急傾斜地崩壊危険箇所と土砂災害警戒区域の違いは,調 査精度にあり,土砂災害警戒区域の方が,調査精度が高い状 況にある.この要因は,急傾斜地崩壊危険箇所の調査が,国 土交通省(当時建設省)砂防課長通達に基づいて行われた一 方で,土砂災害警戒区域は,法律に基づいて指定された区域 であり,高い厳密性が求められる所にある.実際にそれぞ れの調査方法を比較すると,急傾斜地崩壊危険箇所の調査 では,地形図や空中写真による机上抽出と現地確認が行わ れている.机上抽出では,縮尺が2万5千分の1の地図を 用いるため,抽出が粗い傾向にあり,現地確認も実施箇所が 少ない状況にある*1.一方で,土砂災害警戒区域の調査で は,縮尺が2千5百分の1の地形図と空中写真による机上 抽出と,全箇所の現地確認が実施されている*1.そのため, 後者の方が調査精度が高く,より正確な情報となっている.

本研究では,正解データに急傾斜地崩壊危険箇所を用い る場合と,土砂災害警戒区域を用いる場合でシミュレーショ ンを行い,それぞれの傾向を考察する.



図 4 本研究における pix2pix の構成

3.4 モデルの構成と学習

本節では、赤色立体地図と空中写真から急傾斜地崩壊危 険箇所(以下,危険箇所と呼ぶ)と、砂災害警戒区域(以下, 警戒区域と呼ぶ)を示す画像を生成する pix2pix モデルの 構成と学習について説明する.pix2pix の構成は図4の通り である.入力に用いられる赤色立体地図は傾斜量と曲率を 表現した地図で急傾斜地の情報を有しており、空中写真か らは家屋の有無を確認することができる.これらの画像を 入力に用いることで、急傾斜地と家屋の有無を考慮した危 険箇所と警戒区域の推定が可能になると考えられる.複数 の画像を入力に用いる際の実装は pix2pix for Map tiles[11] を利用する.

生成器は図5に示すようなU-Net構造のネットワークを 用いる. サイズが 256×256, 2 チャネルの赤色立体地図と 3 チャネルの空中写真を入力として, Encoder で畳み込みに よりダウンサンプリングしながら重みフィルタの数の深さ を持つ特徴マップを抽出する. その後, Decoder で逆畳み込 みによりアップサンプリングしながら特徴マップから画像 を形成していき、サイズが256×256、3 チャネルの危険箇所 画像を出力する. Encoder の畳み込み処理では、入力に対 して重みフィルタの内積を計算し活性化関数を適用する処 理を,重みフィルタの位置をスライドさせながら繰り返す. ここで stride は重みフィルタをスライドする間隔である. zero padding は入力画像の縁の領域を0 で埋める処理で、 端の領域が他の領域に比べて畳み込まれる回数が少なくな ることを防ぐために行う. 図5中の zero padding:1は zero padding を行う領域幅が1であることを表す. Decoder の 逆畳み込み処理では、入力の各ピクセルの間と周囲に0を 入れ込んでサイズを拡大した後に畳み込み処理を適用する. 活性化関数やフィルタのサイズなどのハイパーパラメータ については pix2pix の論文 [3] の著者の実装 [12] を参考に 選択した.

識別器のネットワークは図6に示すようなPatchGAN を用いた畳み込みニューラルネットワークで、「正解の危険

^{*1} 東京都建設局への問い合わせで得た回答に基づく情報である.

IPSJ SIG Technical Report





赤色立体地図 空中写真

箇所と空中写真,赤色立体地図」の本物のペア画像もしく は「生成器が生成した危険箇所と空中写真,赤色立体地図」 の偽物のペア画像が入力され,畳み込み処理を経てパッチ 単位で本物のペアである確率を出力する.出力を確率値と するため,最後の畳み込み処理における活性化関数に0か ら1の範囲に正規化するシグモイド関数を用いる.識別器 のハイパーパラメータについては pix2pix の論文[3]の著 者の実装[12] を参考に選択した.

学習は図7に示すように,2.2.2節の式(1),(2)の損失関数 *L_D* と *L_G* を最小化するように,誤差逆伝搬法により生成器と識別器の畳み込み処理で用いられるフィルタの重みパラメータの更新を行う.

推定の際は、判定対象領域の赤色立体地図と空中写真の 画像を生成器に入力する.生成器からの出力画像が危険箇



図8 改善手法1での学習の概要

所の推定画像となる. この出力画像全体を危険箇所の推定 結果として用いる場合, 出力画像の縁の部分は周囲の傾斜 や家の有無の情報が考慮されないため, 推定精度が下がる と考えられる. そのため, 出力画像の中心部の P×P の領域 のみを推定結果として用いることとする.

3.5 従来の改善手法

本項では, [13] で提案された従来の改善手法について説 明する.

3.5.1 改善手法 1: タイル画像を用いた推定法の改善

急傾斜地崩壊危険箇所や土砂災害警戒区域(急傾斜地崩 壊)は、急傾斜地及びその周囲で人家等への被害が想定さ れる場所と定義されており、周囲状況が関係している.3.4 節の最後で述べたように、図7の本研究における pix2pix の学習では、タイル画像の縁の部分の出力は周囲状況が考 慮されることなく決定されていると考えられる.したがっ て、pix2pixの従来モデルで行われているように、画像の縁 の部分を含む出力画像全体を学習に用いると精度が低下し ている可能性がある.そこで改善手法1では、図8に示す ように、損失関数を256×256ピクセルの各タイル画像の中 心部 Q×Q のみを用いて計算を行い、学習を行う.図8に おいて、画像中心部のグレーの部分が損失関数が適用され る Q×Q の部分である.

3.5.2 改善手法 2: 不安定な学習の改善

pix2pixの従来モデルの損失関数を用いると, 生成器に 対して識別器の性能が高すぎることから学習が不安定にな る. そのために考えられたのが改善手法 2 である. 生成器 に対して識別器の性能が高すぎる状態は生成器が識別器を 全く騙せていない状態で, 識別器に偽物のペアを入力した 時の出力が 0 に近い値となる. この状態では式 (4)の生成 器についての敵対的ロス L_{advG} が図 9(a)のように大きな 値となり学習が不安定となる. そこで, 学習の安定化をは かるため, 改善手法 2 では, 式 (3), (4)の損失関数において, $L_{advD} \ge L_{advG}$ を式 (6), (7)のようにヒンジ関数で定義し たものを用いる. 図 9(b) に, 式 (6), (7)の本モデルの敵対 的ロスを示す.

L_advG L_advD L_advG L_advD 4 3 ₽ ₽ ₩ ³ 쯲₂ 損1 0 0 -1 0.4 0.6 0.4 識別器の出力(入力:偽物のペア画像) 識別器の出力(入力:偽物のペア画像) (a) 従来モデル (b) 改善手法 2 図 9 従来モデルと改善手法 2 の敵対的ロス 予測クラス P(危険) N(非危険) Ρ 偽陰性 実際のクラス 真陽性 (危険 (TP) (FN) N (非 偽陽性 真陰性 危 (FP) (TN) 険 正解(True) 不正解(False) 図 10 混同行列

$$L_{advD} = \max(0, D(G(x)) + 1) + \max(0, -D(x, y) + 1)$$

$$L_{advG} = -D(G(x)) \tag{7}$$

3.6 提案手法 1: 危険箇所の再現率を重視した学習

本研究では、評価指標に再現率、適合率、F値を用いてい る.この中でも特に、「実際に危険箇所であるうち正しく危 険箇所と予測した割合」を表す再現率は、人命に関わるこ ともある土砂災害の危険箇所を見逃さないために重視する べき指標である.しかし、これまで再現率を考慮した学習 は行えていなかったため、再現率の改善を目指すことが難 しい状況であった.そこで再現率を重視するために、正解 画像と生成画像の差の絶対値の和 L_{L1} において、生成画像 の誤り方に重みを付ける手法を提案する.

生成画像の誤りパターンは、図10に示させるような混同 行列に従う. 混同行列は,モデルの予測結果を真陽性 (True Positive), 真陰性 (True Negative), 偽陽性 (False Positive), 偽陰性 (False Negative) の4つの観点で分類し,それぞれ に当てはまる予測結果の個数をまとめた行列である.予測 結果が不正解であるデータは偽陽性と偽陰性の2種類存在 する.

図 11 に本提案手法を示す.本提案手法では混同行列を求 めるため,損失関数の計算を行う前に,RGBの正解画像と 生成画像をグレースケール処理と2値化処理により2値画 像に変換している.2値画像から生成画像における偽陰性



図 11 再現率を重視する提案手法

FN の総和と偽陽性 FP の総和をそれぞれ計算し, これら 2 つの重み付き和を新たな L1 ノルム損失 L_{L1} とする. この 時, 偽陽性の重み ω_{FP} に対して偽陰性の重み ω_{FN} を大き くすることで偽陰性 (FN) により大きなペナルティを与え て再現率を重視する.

3.7 提案手法 2: 損失関数への正則化の適用

機械学習においてモデルの学習を行う際,過学習がしば しば問題になる.過学習とは、モデルが学習データに適合 しすぎることにより,汎化性能が落ちた状況に陥った状態 である.正則化はこの過学習を抑える代表的な方法の1つ で,損失関数に正則化項を加えて最適化を行う.これによ り,中間層と出力層における極端な重みパラメータにペナ ルティを課すことで過学習を抑制する.正則化の手法とし てL1 正則化やL2 正則化などがある.

m 次元の重みベクトル ω の L1 正則化は式 (8) に示す通 り,各要素の絶対値の和で定義される.ここで, λ_{L1} , λ_{L2} は 正の定数のハイパーパラメータであり,この大きさに比例 して正則化の効果が強くなる.L1 正則化は,余分な特徴量 の重みが0となる特徴量削減,次元圧縮の効果がある.

$$\frac{\lambda_{L1}}{2} \parallel \omega \parallel_1 = \frac{\lambda_{L1}}{2} \sum_{j=1}^m |\omega_j| \tag{8}$$

一方, L2 正則化は式 (9) に示す通り, 各要素の 2 乗和で定 義される. L2 正則化は, 重みの大きさに応じてその重みを 0 に近づけることで, 学習データへのモデルの依存を減ら す効果がある.

$$\frac{\lambda_{L2}}{2} \parallel \omega \parallel_2^2 = \frac{\lambda_{L2}}{2} \sum_{j=1}^m \omega_j^2 \tag{9}$$

pix2pix は, 生成器と識別器の2つのモデルで構成され る.本研究では, 危険箇所画像を生成する生成器に正則化 を適用する.また, 事前実験により, 用いる正則化は, L2正 則化のみとした.

3.8 提案手法 3:入力画像に標高タイルを追加

急傾斜地崩壊危険箇所及び,土砂災害警戒区域は「急傾 斜地 (傾斜度 30 度以上かつ高さ 5m 以上の土地)及びその 周囲で人家等への被害が想定される箇所」として調査,公 表されている.これまで,入力画像は急傾斜地の情報とし て赤色立体地図 (傾斜量を赤の彩度,尾根谷度を明度として IPSJ SIG Technical Report

表した画像), 家屋の情報として空中写真を用いていた.しかし, 赤色立体地図は標高の情報を持っていないため, 急傾斜地の情報として不十分であると考えられる.そこで, 新たに入力画像に標高タイル [14], [15] を加えることを検討する.

標高タイルは標高値を RGB 値で格納した画像である. 具体的には,標高値をデータセット毎に規定される標高値 の分解能 u[m] で割って 24 ビットの符号付き整数に変換 し,上位から 8 ビットずつ R, G, B に分解し画素値として 保存している.標高値が存在しない場合は無効値 (NA) と する.無効値の RGB 値は (r,g,b) = (128,0,0) である.画 素値 (RGB 値) から標高値 h[m] の計算式は式 (10), (11) の ように表される.

$$x = 2^{16}r + 2^8g + b \tag{10}$$

$$h = \begin{cases} xu & (x < 2^{23}) \\ NA & (x = 2^{23}) \\ (x - 2^{24})u & (x > 2^{23}) \end{cases}$$
(11)

ここで, *r*, *g*, *b* は RGB 画素値, *h* は標高値 [m], *u* は標高分 解能 [m] である.

4. シミュレーション

4.1 シミュレーション条件

入力画像を赤色立体地図と空中写真とし,正解画像を急 傾斜地崩壊危険箇所の画像もしくは,土砂災害警戒区域の 画像とする.急傾斜地崩壊危険箇所の推定、土砂災害警戒 区域の推定いずれの場合も,学習データは,福岡県北部から サンプリングした危険箇所画像と同地点の赤色立体地図, 空中写真を2万組用いた.検証データとテストデータは、 学習データと同様にサンプリングした危険箇所画像と同地 点の赤色立体地図, 空中写真の 1000 組をそれぞれ用いた. サンプリング範囲は、緯度が 33.333306 度から 33.999972 度, 経度が 130.000027 度から 131.000026 度となっている. 赤色立体地図はアジア航測(株)が作成した赤色立体地図 RRIM(R)5+,標高タイルと空中写真は国土地理院の地理院 タイル (標高タイル: ズームレベル 14, 空中写真: ズームレ ベル17),急傾斜地崩壊危険箇所と土砂災害警戒区域の画像 は、国土交通省国土政策局の国土数値情報データの土砂災 害危険箇所データと土砂災害警戒区域データ (福岡県提供 資料より作成)を用いた. pix2pix のパラメータを表1に示 す. 学習の最適化手法は Adam を用い, 学習率 α = 0.0002,

4.2 評価指標

評価指標には,式(12),(13),(14)で算出される危険箇所 に対する再現率 *Recall*,適合率 *Precision*, F1 スコアを用 いる.ここで,TP は危険箇所を危険箇所であると正しく予

表1 pix2pix のパラメータ

画像サイズ	256 × 256 ピクセル
バッチサイズ	1
λ	100
識別器のパッチサイズ	70
推定に用いる出力画像の中心範囲 P×P	100×100 ピクセル
損失関数を適用する画像の中心範囲 Q×Q	100×100 ピクセル

測できた数, TN は非危険箇所を非危険箇所であると正し く予測できた数, FP は非危険箇所を間違って危険箇所と 予測した数, FN は危険箇所を間違って非危険箇所と予測 した数である.再現率は実際に危険箇所であるうち危険箇 所と正しく予測された割合で,適合率は危険箇所と予測さ れたうち実際に危険箇所である割合を表す.F値は再現率 と適合率の調和平均である.本研究では,実際の危険箇所 を見逃さないために再現率を重視する.

$$Recall = \frac{TP}{TP + FN} \tag{12}$$

$$Precision = \frac{TP}{TP + FP} \tag{13}$$

$$F1 = 2\frac{Recall \times Precision}{Recall + Precision}$$
(14)

4.3 シミュレーション1

従来の改善手法(以降,従来手法と呼ぶ)と提案手法1の 精度比較を行い,再現率を重視しリスク地形の見逃しを防 ぐ提案手法1の有効性を検証する.初めに検証データを用 いて,提案手法1においてハイパーパラメータωFNの最適 化を行い,最適な学習回数を決定した後,テストデータを用 いて精度の比較を行う.最適化は,検証データにおける再 現率が99%以上となった上で,適合率ができるだけ高い値 をとるように行う.

4.3.1 シミュレーション1結果

危険箇所の推定と警戒区域の推定における学習データと 検証データでの評価結果をそれぞれ表 2,表 3 に示す.ここ で表中の学習回数の列における太字は最良値の学習回数, 学習と検証の列における太字は各評価指標が高かった値を 示す.最適な学習回数を決定する際は、「危険箇所の見逃し を評価する再現率が 99.0%以上かつ,適合率が高い」とい う基準で決定している.更に,最適な学習回数におけるテ ストデータでの提案手法と従来手法の比較結果を表 4 に示 す.表4を見ると,危険箇所と警戒区域ともに、テストにお いて再現率が 100%近い結果が得られ,危険箇所の見逃し をほどんど無くすことができた.一方で,再現率とトレー ドオフの関係にある適合率が非常に低い結果となり、それ により F 値も低下していた.

4.4 シミュレーション 2

提案手法1と提案手法2を併用する手法と提案手法1の

情報処理学会研究報告

IPSJ SIG Technical Report

100	E_{E} , $\omega_{FN} = 1200.0$, $\omega_{FP} = 1.00[70]$					
学習		学習			検証	
回数	再現率	適合率	F 値	再現率	適合率	F 値
10	99.75	0.97	1.92	99.08	1.16	2.30
12	99.22	1.00	1.98	97.71	1.24	2.45
14	99.90	0.98	1.94	95.64	1.18	2.32
16	100.0	0.98	1.93	99.91	1.22	2.41
18	100.0	0.98	1.94	98.66	1.22	2.41

表 3 シミュレーション 1 の結果 (手法 1, 土砂災害警戒区域の推定, ω_{FN} = 1300.0, ω_{FP} = 1.0)[%]

	10 -000		=)[,.			
学習		学習			検証	
回数	再現率	適合率	F 値	再現率	適合率	F 値
12	99.96	1.06	2.10	100.0	1.10	2.18
14	99.88	1.07	2.12	99.05	1.11	2.20
16	99.98	1.07	2.11	99.81	1.12	2.21
18	99.93	1.07	2.12	98.40	1.12	2.21
20	99.45	1.10	2.17	96.20	1.15	2.28

表 4 テストデータにおける提案手法と従来手法の比較結果 [%]

		最適な		テスト	
		学習回数	再現率	適合率	F 値
急傾斜地崩壊	手法 1	16	100.0	0.96	1.91
危険箇所の推定	従来手法	120	27.97	3.20	5.74
土砂災害警戒	手法 1	16	99.98	0.93	1.84
区域の推定	従来手法	60	49.67	10.27	17.01

みを用いる場合と比較して, 正則化を用いる提案手法2の 有効性を検証する. 初めに検証データを用いて, 提案手法 1と提案手法2を併用する手法においてハイパーパラメー $g \omega_{FN} \ge \lambda_{L2}$ の最適化を行い, 最適な学習回数を決定し た後, テストデータを用いて精度の比較を行う. 最適化は, 検証データにおける再現率が99%に近い値をとった上で, 適合率ができるだけ高い値をとるように行う. 正則化を用 いる提案手法2では, L2 正則化を生成器のみに適用する.

4.4.1 シミュレーション2結果

危険箇所と警戒区域の推定における学習データと検証 データでの評価結果を表5,6に示す.ここで表中の学習回 数の列における太字は最良値の学習回数,学習と検証の列 における太字は各評価指標が高かった値を示す.最適な学 習回数を決定する際は,「危険箇所の見逃しを評価する再 現率が99.0%以上かつ,適合率が高い」という基準で決定 している.更に,最適な学習回数におけるテストデータで の提案手法と従来手法の比較結果を表7に示す.表7を見 ると,危険箇所推定では,適合率とF値の改善があった.一 方で適合率が改善した分,再現率は低下していた.警戒区 域では,再現率,適合率が共に0.02%改善していた.危険箇 所推定と警戒区域どちらにおいても,正則化適用のはっき りとした有効性は確認できなかった.

4.5 シミュレーション3

提案手法1,提案手法2及び提案手法3を併用する手法に

表 5 シミュレーション 2 の結果 (手法 1·2, 急傾斜地崩壊危険箇所

	の推定, $\omega_{FN} = 300.0, \omega_{FP} = 1.0, \lambda_{L2} = 0.001)[\%]$						
学習		学習			検証		
回数	再現率	適合率	F 値	再現率	適合率	F 値	
20	78.06	1.30	2.55	58.56	1.88	3.64	
40	96.15	1.23	2.43	91.74	1.57	3.09	
60	98.17	1.08	2.15	99.67	1.49	2.94	
80	83.15	2.23	4.35	66.25	2.90	5.56	
100	93.60	1.60	3.14	81.19	2.15	4.19	

表 6 シミュレーション 2 の結果 (手法 1.2, 土砂災害警戒区域の推

定,	$\hat{\kappa}, \omega_{FN} = 300.0, \omega_{FP} = 1.0, \lambda_{L2} = 0.007)[\%]$					
学習		学習			検証	
回数	再現率	適合率	F 値	再現率	適合率	F 値
10	99.50	1.09	2.15	99.68	1.14	2.25
12	99.72	1.08	2.14	99.51	1.14	2.25
14	98.52	1.14	2.25	95.79	1.20	2.38
16	97.36	1.18	2.33	99.16	1.31	2.58
18	99.89	1.09	2.16	99.44	1.19	2.34
20	98.43	1.14	2.24	93.76	1.19	2.34

表 7 テストデータにおける提案手法と従来手法の比較結果 [%]

		最適な		テスト	
		学習回数	再現率	適合率	F 値
急傾斜地崩壊	手法 1, 2	60	99.43	1.34	2.64
危険箇所	手法 1	16	100.0	0.96	1.91
土砂災害警戒	手法 1, 2	16	99.60	1.10	2.17
区域	手法 1	16	99.98	0.93	1.84

ついて,提案手法1と提案手法2を用いる場合と比較し,入 力画像に標高タイルを追加する提案手法3の有効性を検証 する.初めに検証データを用いて,提案手法1,提案手法2 及び提案手法3を併用する手法においてハイパーパラメー タ ω_{FN} と λ_{L2} の最適化を行い,最適な学習回数を決定し た後,テストデータを用いて精度の比較を行う.最適化は, 検証データにおける再現率が99%に近い値をとった上で, 適合率ができるだけ高い値をとるように行う.正則化を用 いる提案手法2では,L2正則化を生成器のみに適用する. **4.5.1** シミュレーション3結果

危険箇所と警戒区域の推定における学習データと検証 データでの評価結果を表8,9に示す.ここで表中の学習回 数の列における太字は最良値の学習回数,学習と検証の列 における太字は各評価指標が高かった値を示す.最適な学 習回数を決定する際は,「危険箇所の見逃しを評価する再 現率が99.0%以上かつ,適合率が高い」という基準で決定 している.更に,最適な学習回数におけるテストデータで の提案手法と従来手法の比較結果を表10に示す.表10を 見ると,危険箇所の推定では,再現率と適合率,F値の結果 が悪くなっていた.特に再現率は6.42%低下している.3.3 項でも述べた通り,急傾斜地崩壊危険箇所の調査が比較的 簡単なものであったことから,急傾斜地崩壊危険箇所の推 定において,入力画像に標高タイルを追加する有効性が無 い結果となったと考えられる.警戒区域の推定では,再現

情報処理学会研究報告

IPSJ SIG Technical Report

	$M_{V} = 1900.0, \omega_{FP} = 1.0, \lambda_{L2} = 0.001)[70]$						
学習		学習			検証		
回数	再現率	適合率	F 値	再現率	適合率	F 値	
16	99.94	1.14	2.25	83.95	1.23	2.43	
18	97.61	1.19	2.34	78.33	1.34	2.63	
20	99.91	1.14	2.26	84.14	1.25	2.45	
22	99.87	1.15	2.28	83.83	1.27	2.51	
24	99.76	1.15	2.28	83.82	1.28	2.53	

表 8 シミュレーション 3 の結果 (手法 1~3, 急傾斜地崩壊危険箇 所の推定 ω_{EN} = 1900.0 ω_{EP} = 1.0. λ_{L2} = 0.001)[%]

表 9 シミュレーション 3 の結果 (手法 1~3, 土砂災害警戒区域の

推定, $\omega_{FN} = 600.0$, $\omega_{FP} = 1.0$, $\lambda_{L2} = 0.01)$ [%]						
学習		学習			検証	
回数	再現率	適合率	F 値	再現率	適合率	F 値
20	97.83	1.66	3.27	92.04	2.37	4.63
22	98.66	1.51	2.97	96.85	2.22	4.33
24	99.39	1.45	2.85	99.32	2.14	4.20
26	99.29	1.47	2.91	98.10	2.13	4.16
28	97.47	1.72	3.39	92.78	2.49	4.85

表 10 テストデータにおける提案手法と従来手法の比較結果 [%]

		最適な		テスト	
		学習回数	再現率	適合率	F 値
急傾斜地崩壊	手法 1 ~ 3	20	93.01	1.09	2.15
危険箇所	手法 1·2	60	99.43	1.34	2.64
土砂災害警戒	手法 1 ~ 3	24	99.94	1.77	3.47
区域	手法 1·2	16	99.60	1.10	2.17

率が 0.34%, 適合率が 0.67%, F 値が 1.30%改善した. この 結果から, 入力画像に標高タイルを用いることは, 土砂災害 警戒区域の推定においては有効であるといえる.

5. おわりに

本稿では、pix2pix を用いた地図画像等からの急傾斜地崩 壊危険箇所及び,土砂災害警戒区域の効果的な推定法につ いて検討を行った.タイル画像の中心部のみを損失関数に 用いる手法と不安定な学習を改善する手法を適用した従来 法に対して、リスク地形の見逃しを無くすために再現率を 重視する損失関数を提案するとともに, 過学習対策として の正則化適用、入力画像に標高タイルを新たに用いる手法 を検討した.シミュレーションにより、再現率を重視する 損失関数を用いることで再現率が 99%以上まで改善し、リ スク地形の見逃しを無くすことができる事を示した.正則 化の適用においては、改善した部分があったもののわずか な違いであったため、はっきりとした有効性は確認できな かった.入力画像に標高タイルを新たに用いる手法におい ては、急傾斜地崩壊危険箇所の推定では精度の低下が見ら れた一方で, 土砂災害警戒区域の推定では精度の改善があ り有効性が確認できた.この違いは、危険箇所と警戒区域 の調査方法の違いによるものであると考えられる. 今後の 課題は, 検証時の精度低下を防いだ上での学習における精 度向上と、学習データに含まれない場所を正しく推定でき るようにすることである.

参考文献

- 高山陶子,濱田耕平,花井健太,織田和夫,角田里美,"ディー プラーニングと赤色立体地図を用いた微地形自動判読手 法の検討",第67回平成30年度砂防学会研究発表会概要 集,pp. 697-698, 2017.
- [2] 岩崎亘典,和山亮介, "Deep Learning での地図タイル活 用の検討", 第 31 回人工知能学会全国大会論文集, 2B1-5, 2017.
- 古木宏和,稲垣裕,一言正之,櫻本智美,藤平大,"深層 学習を用いた地すべり地形自動抽出の試みと教師データの影響",第67回平成30年度砂防学会研究発表会概要集, pp. 145-146, 2017.
- [4] 千葉達朗,鈴木雄介,平松孝晋,"地形表現手法の諸問題 と赤色立体地図",日本地図学会,Vol.45,No.1,pp. 27-36, 2007.
- [5] 戸田堅一郎,"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, pp. 75-79, 2014.
- [6] 山下悠也,重井徳貴,杉本知史,高江洲竜馬,石塚洋一, "CNN を用いた立体地図と空中写真からの土砂災害の危険箇所推定",土木学会西部支部研究発表会,pp. 339-340, 2019.
- [7] Ian J. Goodfellow, Jean Pouget-Abadie, Megdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Vourville and Yoshua Bengio, "Generative Adversarial Networks", arXiv preprint arXiv:1406.2661, 2014.
- [8] P. Isola, J.-Y. Zhu, T. Zhou and A. A. Efros, "Imageto-Image Translation with Conditional Adversarial Networks", arXiv preprint arXiv:1611.07004, 2016.
- [9] 国土交通省,土石流危険渓流及び急傾斜地崩壊危険箇所に 関する調査結果の公表について,2003.
- [10] 東京都建設局,用語の解説:土砂災害警戒区域(通称:イエローゾーン)・土砂災害特別警戒区域(通称:レッドゾーン), https://www.kensetsu.metro.tokyo.lg.jp/jigyo/ river/dosha_saigai/map/kasenbu0087.html(2021 年 12月20日現在)
- [11] GitHub, NARO-41605/pix2pix_map_tiles, https:// github.com/NARO-41605/pix2pix_map_tiles.
- [12] GitHub, phillipi/pix2pix, https://github.com/ phillipi/pix2pix.
- [13] 西結人, 重井徳貴, 杉本知史, 石塚洋一, 宮島廣美, "Pix2Pix を用いた急傾斜地崩壊危険箇所の推定", 2020 年度電子情 報通信学会九州支部学生会講演会講演論文集, D-33, 2020.
- [14] 国土交通省,地理院地図 | 標高タイルの詳細仕様, https://maps.gsi.go.jp/development/demtile. html(2020年11月10日現在).
- [15] 西岡芳晴, 長津樹理, "PNG 標高タイルー Web 利用に適 した標高ファイルフォーマットの考察と実装ー", 情報地 質第 26 巻第 4 号, 2015.