

深層学習に基づく土砂災害および ため池災害の規模の推定に関する基礎的研究

FUNDAMENTAL RESEARCH ON THE ESTIMATION OF THE SCALE OF SEDIMENT AND RESERVOIR DISASTERS BASED ON DEEP LEARNING

和田 光真¹⁾, 久保 栞²⁾, 吉田 秀典³⁾

Mitsumasa WADA, Shiori KUBO and Hidenori YOSHIDA

- 1) 香川大学大学院工学研究科 (〒761-0396 香川県高松市林町 2217-20, E-mail: s15d401@stu.kagawa-u.ac.jp)
2) 香川大学大学院工学研究科 (〒761-0396 香川県高松市林町 2217-20, E-mail: s18d401@stu.kagawa-u.ac.jp)
3) 香川大学創造工学部 (〒761-0396 香川県高松市林町 2217-20, E-mail: yoshida.hidenori@kagawa-u.ac.jp)

The damage information by sediment-related disaster included reservoir disaster is important to implement reconstruction assistance early. However, organizing various disaster information takes a long time and needs special knowledge. In this study, the scale of sediment-related disaster included reservoir disaster is estimated objectively based on deep learning. As a result, the deep learning model using aerial photographs after a heavy rain disaster was able to objectively estimate the damage situation by detecting each judgment area.

Key Words: sediment disaster, reservoir disaster, deep learning, CNN

1. 緒言

近年、多発する豪雨等による土砂災害およびため池災害のリスクが高まる中、防災・減災のみならず、災害発生後の復旧・復興の取り組みを円滑に進めることが求められている⁽¹⁾。復旧・復興の迅速な対応のためには、災害状況をいち早く把握し、かつ客観的な情報の整理が必要となる。災害後の地形情報の収集方法は様々であるが、詳細な地形データを取得できる例として、航空レーザー計測が採用されている。菊池ら⁽²⁾は、航空レーザー計測の情報を分析して地すべりおよび斜面崩壊の状況を定量的に取得する方法を提案した。また、乾ら⁽³⁾は、平成 28 年熊本地震で地すべりが発生した森林域における航空レーザー計測による斜面調査結果を治山施設の復旧に有益な情報として提供した。これらの詳細な地形情報を活用することによって、きめ細かい復旧・復興計画が策定可能となっている。しかしながら、航空レーザー計測の実施およびデータ処理には専門的な知識が必要な上に計測

機器も特殊のため、どのような災害状況であっても手軽に情報収集ができるとは限らない。

災害状況を分析するための新たな手法として、人工知能による分析手法が活発化している。例えば、岡崎ら⁽⁴⁾は、建物データベースを利用したディープラーニングによる建物特性の抽出と台風被害の予測手法を開発した。また、植田ら⁽⁵⁾は、災害前後の衛星電波を利用した詳細な地形が得られる SAR 画像と航空レーザー測量データによる地形データ (DEM データ) を用い、人工知能の手法である畳み込みニューラルネットワーク (Convolutional Neural Network: CNN⁽⁶⁾) による土砂災害の検出手法を開発した。これらの手法も前述と同様に、高度な調査によって取得した詳細なデータベースを基にしており、高精度ではあるが、災害直後の分析データが整うまでには時間を要するため、緊急用には不向きである。現時点において、実際の災害現場で活躍できる調査用装備としては、空中撮影が可能であるヘリコプターやドローンがある。篠原ら⁽⁷⁾は、平成 26 年 (2014 年) 8 月広島豪雨において、土砂災害現場の最前線で救助を行った消防隊員への聞き取

り調査で、災害情報を把握する上で特に有効であった装備の一つにドローンによる撮影が挙げられており、従来のヘリコプターによる空中撮影と同様に高く評価されていたと報告している。このように、現場において実践投入が可能なドローンによる空中写真や動画による情報収集の手法は、当面の間は主力となると考えられ、航空レーザー測量や SAR 画像等による詳細な調査は後日実施するとしても、災害直後の迅速な実態把握を目的とした調査方法としては、有効な手段と考える。そこで本研究では、土砂災害後に撮影された空中写真を用い、災害状況を自動検知する人工知能の開発を目的とした基礎的な研究を行う。人工知能を学習させるための手法として、CNN を利用する。CNN を災害画像に適用すると、災害の画像において特徴となる部分を自動で認識するモデルが構築される。一方、CNN による手法は大量のサンプル画像が必要となるため、災害後の空中写真を撮影した事例が少ない状況において、被害の判定に採用できるものは限られ、解析精度に課題を残すという指摘（例えば、文献⁽⁸⁾）がある。筆者らの研究⁽⁹⁾においても、ため池の氾濫が発生した豪雨災害を想定し、CNN による家屋の被害判定を実施したものの、データ数が少ないため、精度の向上が課題であった。そこで本研究では、比較的サンプル数が多い土砂災害およびため池災害の空中写真に着目し、これらの災害を自動検知するための基礎的な研究を実施した。災害後の空中写真によって被害状況を把握することができれば、目視等の人間による評価よりも客観的に、かつ迅速に被災状況を把握することが期待できる。本論文では、2 章にて畳み込みニューラルネットワーク（CNN）を用いた学習手法を説明し、3 章において、その学習データを利用して、土砂災害およびため池災害の被害状況を推定する。4 章のまとめでは、同手法の活用方法と今後の課題について考察する。

2. 計算理論

2.1. CNN による学習

本研究において設定する CNN による学習フロー全体を Fig. 1 に示す。また、各々の処理に関しては、大きく 3 つに分類し、前半の処理に関する説明からは始める。

Fig. 2 に示す Convolution（畳み込み）は、元データである RGB 画像にフィルタを乗じ、バイアスを加算することで元データの容量を小さくする。元データの空中写真における画像下のカッコ内の 4 つ数値（32, 3, 224, 224）は、順に、並列処理を実施する画像の枚数を意味するバッチ数（本研究では 32 枚に設定）、RGB カラーの色の種類（3 種類）、画像の大きさ（224 ピクセル× 224 ピクセル）をそれぞれ意味する。図中のフィルタとは、元画像に乗じることで色や形の境界を強調するといった様々




Fig.1 Overall flow chart of convolution neural network




Fig.2 Convolution: Filters the RGB image of the original data and adds a bias to reduce the capacity of the original data.

な画像の特徴（重み）のパターンを抽出する。図中のフィルタの数値（64, 3, 7, 7）は順に、CNN において 2 の累乗が用いられるため、フィルタを 6 乗して 64 種類、RGB カラーの色別（CNN ではチャンネルと定義）の 3 種類、フィルタの大きさを設計値として 7×7 の配列と設定する。元データとフィルタとを乗じると、フィルタの種別毎に数値が強調された重みができる。畳み込みデータを y_n と定義すると、それぞれの関係は、Eq. (1) で示される。

$$y_n = x_n \omega_n + b \quad (1)$$

ここで、 n 番目の元画像を x_n 、フィルタを ω_n 、バイアスを b とする。バイアスとは、フィルタと同じ数の 1 次元配列で構成さ

Batch Normalization

A method of forcibly optimizing the output of a layer so that the distribution of parameters in the middle layer is appropriate.




Fig3 Batch normalization: Reduce data bias by averaging and distributing numbers without resizing convolution data.

れ、画像とフィルタとの重みに対して一律の値を重みに上乗せすることによって、閾値を超える際の発火のし易さを調整する役割をもつ。

次に、Fig. 3 に示す Batch Normalization⁽¹⁰⁾ (バッチ正規化) の処理について説明する。正規化とは、畳み込みデータ配列の大きさは変えず、数値の平均化と分散化によってデータの偏りを減らす処理のことで、Eq. (2), (3), (4), (5) にて定義される。

$$\frac{1}{k} \sum_{i=1}^k x_i \rightarrow m_n \quad (2)$$

$$\frac{1}{k} \sum_{i=1}^k (x_i - m_n)^2 \rightarrow v_n^2 \quad (3)$$

$$\frac{x_i - m_n}{\sqrt{v_n^2 + \epsilon}} \rightarrow \hat{x}_i \quad (4)$$

$$\gamma \hat{x}_i + \beta \rightarrow y_i \quad (5)$$

ここで、Eq. (2) において、 k を学習データの数 (本研究においては 32 枚の画像データ)、 x_i を k 枚毎の学習データの値とすると、 m_n は、学習データ x_i の平均を意味する。ここで、 n は学習データの集合で、 $n = \{x_1, x_2, \dots, x_k\}$ (ミニバッチと定義) とする。次に、Eq. (3) において、学習データ x_i からミニバッチの平均値 m_n を差し引き、その二乗和をデータ数 k で除すると分散 v_n^2 を得る。さらに、Eq. (4) において、学習データの値とミニバッチの平均値の差分を分散の正の平方根 (標準偏差) で除することで、正規化が行われる。なお、正規化された集合は、平均値が 0、分散値が 1 となる。また、 ϵ は 0 値となって計算不能となることを防止するためのごく小さな値を示す。そして、Eq. (5) では、正規化したミニバッチ $\hat{x}_{kn}$ に対して繰り返し学習し、移動平均によって最適化させるための更新パラメーターとして、分散値 γ (初期値 1) による乗算、平均値 β (初期値 0) による加算を与える。正規化は、データを線形変換するのみで元データの出力分布を変えないため、過学習の防止や学習速度の効率化を実現することができる。

Rectified Linear Unit

Set negative values to zero (prevent negative values from backpropagation)




Fig4 ReLU function: An activation function that converts a negative value of normalized data to zero.

Max Pooling

Select the largest for a small area (data compression)




Fig5 Max pooling: Extraction of maximum value.

次に、Fig. 4 に示す Rectified Linear Unit (以下、ReLU) と示す活性化について説明する。ReLU は関数にて定義され、Eq. (6) にて示す。

$$f(x) = \max(0, x) \quad (6)$$

ここで、 x は正規化データを示し、正規化データのマイナス値を 0 に変換する活性化である。この活性化により、不要な負値を無効化することができる。

次に、Fig. 5 に示す Max Pooling による最大値の抽出処理について説明する。ReLU によって活性化されたデータの大きさをここでは 1/2 に圧縮するために、ReLU データ (112×112) 中の小領域 (2×2) の範囲を重複しないようにスライドし、その内において最大の数値のみを抽出して、領域の圧縮 (112×112 から 56×56) 処理を行う。この処理により、小領域に含まれるごく僅かなデータの違いがあっても最大値が優先されることとなり、微小なデータの違いがあっても特徴を絞り込むことができる。

また、中間層における繰り返し処理について説明する。Fig. 6 および Fig. 7 は、全体フローで示した中間層における処理 (BottleNeck A および BottleNeck B と定義) の詳細である。Fig. 6 の BottleNeck A における各処理においては、前述の Convolution, Batch Normalization および ReLU を組み合わせて実施する。




Fig6 Bottleneck A: Intermediate layer processing by type A flowchart.




Fig.7 Bottleneck B: Intermediate layer processing by type B flowchart.

Fig.6の左側にてConvolutionおよびBatch Normalizationを、また、右側にて、ConvolutionとBatch Normalizationの後にReLUの処理を繰り返す。Fig.6に示すように中間層から入ってきた配列(32, 64, 56, 56)は、 1×1 と 3×3 のConvolution層によって一旦、次元を小さくし、後のConvolution(256, 64, 1, 1)で元の次元に戻す。これらの並列処理された配列は、それぞれが最終的に加算され、ReLUの処理を実施する。Fig.7のBottleneck Bにおいては、Bottleneck Aと比べて畳み込み処理と正規化の処理は並行で実施されていない。この二つの処理を組み合わせることで全体フローおよびFig.7の下段で示した中間層の処理(全ての配列を順に示すことは省略する)を繰り返した結果、Bottleneck 中間層後の配列は(32, 2048, 7, 7)に集約され、畳




Fig8 Average pooling: The process of converting a two-dimensional array into a one-dimensional array.




Fig9 Reshape: The process of converting a two-dimensional array to a one-dimensional array.




Fig.10 Linear function: Calculates the sum of weights.

み込み処理の計算量を少なくすることができる。この手法は、本研究において採用しているResNet(Residual Network)⁽¹¹⁾の特徴の一つである。

さらに、全体フローのうち最終段階での処理について説明する。Fig.8に示すAverage Poolingは、Bottleneck 中間層によって小配列の 7×7 へ活性化されたデータを一つの平均値に圧縮し、 1×1 の極小領域へまとめることを示している。さらに、Fig.9に示すReshapeは、Average Poolingによって 1×1 の部分削除するため、2次元配列から1次元配列に変換する処理を行う。そして、Fig.10に示すLinear Functionは、Reshape




Fig.11 Soft cross entropy: Outputs the loss rate due to cross entropy.

データ配列 2048 個と等しい数をもつ重みを乗じてバイアスにて調整することにより、重みの総和（スコア x ）を算出する。

最終的には、Fig. 11 に示すとおり、スコア x を Softmax 関数によって最大値を 1.00 とした確率分布 y に変換し、Cross Entropy（交差エントロピー、Fig. 11 内の式）によって損失率 L （0.00 に近づく）を出力する。ここで、ラベル t は、土砂災害およびため池を含むデータの集合を示し、含まれる場合は 1、含まれない場合は 0 を示す。すなわち、損失率が小さくなるほど、スコア x の値が正解の土砂災害等の数に近いことを示している。

2.2. 学習データの準備

本研究では、空中写真から自動車の台数を推定する手法⁽¹²⁾を応用し、土砂災害によって斜面が露出した箇所およびため池災害によって土砂が堆積した箇所の検出を実施する。まず、教師あり学習を実施するための学習用の地図データを作成する。空中写真のデータは、災害後の空中写真を公開している国土地理院⁽¹³⁾から入手する。入手が容易な公開データを学習用データとして採用できることは社会的にも有用である。次に、入手した地図の画像から災害箇所検知用の学習データを作成する。学習用のデータは、すべて同じサイズ画像に統一する。地図から切り抜く画像サイズが大きくなると、画像のコストも同時に大きくなる。本研究では、計算機の負荷を抑えるため、解像度を 1 ピクセルあたり 35cm とし、1200 × 1200 ピクセル (420m × 420m) の大きさの空中写真を切り取った。そして、それらの収集した画像を徐々に増やし、サンプル画像が 18 枚、サンプル画像をもとに 90 度回転した画像を 18 枚、同様に 180 度回転した画像を 18 枚、合計 54 枚のサンプル数において結果が安定したため、本研究では 54 枚とする。これらの空中写真データに対して、災害箇所（Positive と定義）を土砂災害およびため池災害の被害を受けた可能性が高い箇所と位置づけ、目視によって、災害箇所の中央部に 1 × 1 ピクセルの「点」を追加する（Annotation と定義）。そして、




Fig.12 Class Activation Mapping: A method of highlighting input areas that have contributed to a particular class in an image recognition model.

上記 Positive 以外の構造物（Negative と定義）として田畑、山林、道路、集落等においても同様に点を追加する。このように、元の空中写真の画像が 54 枚、Positive の位置に点のみを追加する画像が 54 枚、同様に Negative の位置に点のみを追加する画像が 54 枚、合計 162 枚の画像を用意する。空中写真のオリジナル画像に、Positive の点を重ねて表示するものと Negative の点を同様にオリジナル画像に重ねて表示する例を Fig. 12 に示す。なお、点の大きさは 1 × 1 ピクセルと小さく判読が難しいため、ここでは点を拡大して表示している。同図の中央における画像は、CAM(Class Activation Mapping)⁽¹⁴⁾により、CNN の学習モデルが災害箇所を正しく認識しているかを確認した結果である。任意の地点において、災害箇所に対して CAM を実施すると、Fig. 12 に示されるとおり、災害の画像において、被害を受けている箇所と被害を受けていない箇所において、色相が異なることを示している。また、同図右端において、点による画像の Annotation 部分と災害箇所の位置とが概ね一致しており、適切に画像が分類されていることを示している。このように、点を追加する教師あり画像を用意し、学習画像として利用することによって、低い解像度であっても精度の良い分析が可能となる。

次に、学習データを作成する。空中写真から切り取った 1200 × 1200 ピクセルの空中写真を ResNet に採用されている 224 × 224 ピクセル (78.4m × 78.4m) の小領域に分割する。本研究では、1200 × 1200 の空中写真から 224 × 224 ピクセルの小領域を等分できないため、相互で重なる領域をもつ訓練データも任意の数作成している。

2.3. 学習データによる訓練

本研究では、更新される写像の最適化を 50 層繰り返した学習済みデータの ResNet50 を利用する。学習率については、Momentum SGD 法⁽¹⁵⁾を利用する。ここで、SGD（確率的勾配降下法, stochastic gradient descent）とは、最適なパラメータ θ より目的関数 $J(\theta)$ を最小化することによって、目的関数の勾配方向 $\nabla_{\theta} J(\theta)$ とは逆方向にパラメータを更新する手法である。




Fig.13 Learning curve showing the correct answer rate




Fig.14 Learning curve showing the loss rate

さらに、上記のSGD法に慣性項(Momentum)を加えることで計算の収束時間を短くなると文献において記されている。現時点の更新ベクトルを $\mathbf{v}_t$ 、過去のタイムステップの更新ベクトルを $\mathbf{v}_{t-1}$ とし、 γ を更新時の割合、学習率を η とすると、Eq. (7)の関係となる。

$$\mathbf{v}_t = \gamma \mathbf{v}_{t-1} + \eta \nabla_{\theta} J(\theta) \quad (7)$$

学習率 η は、文献⁽¹⁶⁾を参考に、学習の反復回数をエポック(Epoch)とすると、30エポックまでを0.01、45エポックまでを0.001、60エポックまでを0.0001とし、更新ベクトルの割合 γ を0.9と設定する。

2.4. 学習結果の検証

CNNでは正解となる画像：訓練(Trainingと定義)データを用いて学習を実施している(教師あり学習)。また、学習済みのモデルの予測精度を確認するため、検証(Validationと定義)データを用いる。学習の進捗を示すため、学習曲線をFig. 13およびFig. 14に示す。ここで、横軸は、学習の反復回数(エポック)を示す。Fig. 13の縦軸は、深層学習による予測値と画像データの特徴量とが一致する割合：正解率(Accuracyと定義)を示しており、推定した値が真の値に近いほど1.0に近づく。また、このグラフの振動が少ないことは、学習に用いたデータは不足して




Fig.15 Distribution of the number of disaster detected in the training data

いないことを示している。同図において、訓練データの正解率と検証データの正解率を同時に表示している。学習の反復回数が進むにつれて、訓練データの正解率が1.0に近づくように最適化されながら推移していることに対し、Validationデータは30エポックあたりから0.85付近に収束しており、50エポックの時点と60エポックの時点とではあまり差が生じていない。正解率としては8割を超えるため概ね妥当であると考えられる。Fig. 14の縦軸は、深層学習による予測値と画像データの特徴量との誤差を収束させるための損失関数のパラメータ(損失率: Lossと定義)に着目する。一般的に、損失が小さくなるほど学習が収束していることを示し、Lossが増加勾配に転ずると過学習であることを表している。Fig. 14において、20エポック付近でやや乱れはあるものの、40エポック以降は順調に収束しており、学習としては概ね妥当な結果を示している。本研究では、Accuracyが概ね収束する50エポック付近の学習モデルを採用することにする。

次に、訓練データにおける災害検知回数の分布状況をFig. 15に示す。ここでの縦軸(Patch count)はデータ数、横軸(Damage number)は土砂災害等として認識した数を示す。同図において、土砂災害等の認識数が0の箇所が1と比べて2倍近い。これは、 224×224 ピクセルの小領域中に土砂災害等の被害が全くない領域も訓練データに加えた結果であるが、必要なデータである。実際の土砂災害では、災害状況や地形に大きく影響するため、災害状況の分布も様々となる。本研究では、災害箇所のみを訓練データに採用すると災害のない箇所の検知精度が低下する可能性があるため、災害が発生していないデータを含む地域を選定している。このように、様々な状況を含む訓練データを用いて学習することは一般的⁽¹⁷⁾であり、本研究においても採用することとした。




Fig.16 Detection of sediment-related disaster included reservoir disaster by aerial photography




Fig.17 Disaster detection in areas with both turbid and non-turbid areas

3. 深層学習モデルによる災害判定

画像処理を施していない空中写真を用いて、学習モデルによる土砂災害およびため池災害の検知を実施する。なお、空中写真は国土地理院（平成 29 年 7 月九州北部豪雨に関する情報）から入手した。判定に使用する空中写真の大きさは、被害地域と無被害地域の両方が含まれる範囲として縦×横：1248 × 1248 ピクセルとする。学習モデルは、224 × 224 ピクセルの大きさに土砂災害およびため池災害の有無を判定するため、Fig. 16 に示すように小領域に分割した範囲毎に災害を検知する。なお、判定エリアの重複を避けるため、外周幅 8 ピクセルの境界領域においては判定対象から除く。判定地域においては、記録的な豪雨の影響で山腹崩壊が発生し、大量の流木をとまう土砂が集落へ流れ込み、それらが山間部の農業用ため池の崩壊を誘発したことにより甚大な被害が発生した。学習モデルは斜面崩壊特有の土砂色およびため池の濁りを検知する。各小領域において示される数値は、検知される回数であり、本研究では数字が大きいほど被害が甚大であると判断する。判定の結果、山腹崩壊を示す線状の部分を検知した。図中央部において数値が 3 を示す箇所においては、小領域に占める山腹崩壊の割合が比較的多いため、学習モデルが強く反応したものと考えられる。また、山間部であっても山腹崩壊していない部分や濁りのないため池においては、検知しなかった。

次に、被害は少ないが、ため池に関する検知精度を確認するため、土砂で濁った箇所と濁らなかった箇所が混在する地域において災害検知を実施する。検知結果を Fig. 17 に示す。図の中央右側の濁ったため池において、災害検知回数が 2 となる。また、




Fig.18 Confusion matrix to understand the detection accuracy of the training model

その他の小領域においては、小規模な崩壊を検知している。一方で、濁りのないため池およびその他の土砂に近い色をしている田畑においては、検知しなかった。

さらに、学習モデルの検知精度を把握するため、Fig. 18 に示す混合行列を表示する。横軸は 224 × 224 の範囲において検知された土砂災害等の検知数を示し、縦軸は実際の値（正解データ）を示す。精度が高いほど対角線上に数値が集まる。本研究での結果は、検知回数が 1 から 4 の範囲においては概ね対角線上に数値が集まっており、この範囲においては良い精度が期待できる。




Fig.19 Disaster detection showing the maximum number of disaster judgments

一方、検知回数が6回において精度が低下するが、小領域における災害箇所が6を示す地域では、小領域の範囲のほとんどが山腹崩壊およびため池が濁っている状態ではない。参考として、Fig. 19に検知結果を示す。検知回数が6となっている箇所において、ごく小規模な山腹崩壊が複雑に分布しており、これが精度低下の原因と考える。したがって、今回のケースに限れば、1から4の検知回数での災害判定であれば、判定精度の客観性は保たれるものとする。なお、山腹崩壊とため池災害を別々に学習すると、検知判定の結果が2種類となるが、このような検知精度の低下は防止できる可能性はある。別の方法として、高解像度の画像を用いるとより精度の高い検知が期待できるが、本研究では、現時点において容易に入手できるドローン等による解像度の空中写真でも判定できることを目的としている。将来的には、高解像度の空中写真が容易に入手できるようになれば、それらを用いて学習モデルを構築することも期待できる。高解像度の空中写真は国土地理院以外から解像度1200dpi相当にて入手可能である。本研究で採用した空中写真の解像度が72dpiであることと比較すると、約16.6倍の差があり、画像のコストの観点からも違いが明らかである。

4. 結言

本研究は、深層学習によって土砂災害およびため池災害の推定規模を見積もるための基礎的な研究を実施した。災害復旧・復興には、国の制度的な課題も指摘されているが、現時点で実施可能な災害規模の見積もりを迅速に行うことができる本研究の災害評

価は社会的意義があると考えられる。加えて、本研究で用いた空中写真は国土地理院の公開データであるため、画像収集のコストを大幅に低減できるため、実用性が高いと考える。災害判定では人の手による手間がかかるが、人工知能による災害検知では、大規模な範囲を短期に判定することも可能で、客観性も確保できる。また、災害前の空中写真と災害後の空中写真とを人間が見比べるのは手間を要するが、本研究のような災害検知結果を併用すれば、概ねの土砂災害およびため池災害の規模を見積もることができる。しかしながら、本研究では土砂災害およびため池災害の災害検知に限定され、実際の災害では家屋の浸水や流出などの様々な状況が想定される。本学習モデルの判定結果を復旧・復興計画にそのまま導入するにあたっては慎重に検討すべきであり、原則、人間による最終判断を補助するためのツールとして使われるべきである。今後の課題として、実際の災害に採用されるような検知精度が求められる。

謝辞

本研究は令和元年度科学研究費補助金（特別研究員奨励費）- 19J14428の助成を受けたものです。

参考文献

- (1) 国土交通省：今後の国土交通行政が向き合うべき課題と方向性，令和2年版国土交通白第3章第1節，<https://www.mlit.go.jp/hakusyo/mlit/r01/index.html>，(2020年10月9日閲覧可)
- (2) 菊地 輝行，崎田 晃基，秦野 輝儀，西山 哲：航空レーザ計測データを用いた地すべり・崩壊斜面における地形判読と地形変状規模の定量化，情報地質(2020)，**31**，**2**，pp. 37-45.
- (3) 乾 光一，吉田 真佐也，佐藤 修治，洲上 翔吾：令和2年7月豪雨による熊本県人吉市および球磨村渡地区の洪水被害の特徴，砂防学会誌(2019)，**71**，**5**，pp. 66-69.
- (4) 岡崎 豪，レブル オリオル：ディープラーニングによる建物特性の抽出と台風被害想定的手法，人工知能学会全国大会論文集，JSAI2017巻，第31回全国大会(2017)，**P1-NFC-00a-4**，p. 3P1NFC00a4.
- (5) 植田 大介，間普 真吾，呉本 亮：災害前後SAR画像とDEMデータを用いたCNNによる土砂災害検出，人工知能学会全国大会論文集，JSAI2018巻，第32回全国大会(2018)，**1D1-02**，p. 1D102.
- (6) Y. LeCun and Y. Bengio: Convolutional networks for images, speech, and time-series, The Handbook of Brain Theory and Neural Networks(1998), pp. 255-258.
- (7) 篠原 徹，酒井 将也，若月 強，中谷 剛，三隅 良平：テキストマイニングを用いた消防職員が大規模土砂災害現場で必

- 要とする消防防災技術と情報共有に関する分析 平成 26 年 (2014 年) 8 月広島豪雨の経験者を対象とした調査 自然災害科学 (2019), **38**, **1**, pp. 55-72.
- (8) T. Valentijn, J. Margutti, M. van den Homberg, J. Laaksonen: Multi-Hazard and Spatial Transferability of a CNN for Automated Building Damage Assessment, Remote Sensing(2020), **12**, **2839**, pp. 1-29.
- (9) 和田 光真, 吉田 秀典: 深層学習によるため池崩壊に伴う建物被害棟数の推定, 計算数理工学論文集 (2019), **19**, pp. 85-90.
- (10) S. Ioffe, C. Szegedy: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, In International Conference on Machine Learning(2015), pp. 448-456.
- (11) K. He, X. Zhang, S. Ren and J. Sun: Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition(2016), pp. 770-778.
- (12) T. Mundhenk, G. Konjevod, W. Sakla and K. Boakye: A Large Contextual Dataset for Classification, Detection and Counting of Cars with Deep Learning, European Conference on Computer Vision (2016), pp. 785-800.
- (13) 国土地理院: 平成 29 年 7 月九州北部豪雨に関する情報, https://www.gsi.go.jp/BOUSAI/H29hukuoka_ooita-heavyrain.html, (2020 年 10 月 9 日現在閲覧可)
- (14) R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, D. Batra: Grad-CAM: visual explanations from deep networks via gradient-based localization, The IEEE International Conference on Computer Vision (2016), pp. 618-626.
- (15) N. Qian: On the momentum term in gradient descent learning algorithms, Neural Networks: The Official Journal of the International Neural Network Society(1999), **12**, pp. 145-151.
- (16) S. L. Smith, P. J. Kindermans, C. Ying, Q. V. Le: Don't Decay the Learning Rate, Increase the Batch Size, International Conference on Learning Representations(2018), 11p.
- (17) 藤田 翔乃, 畑山 満則: 航空写真を用いた深層学習による地震災害時の屋根損傷家屋の把握, 土木学会論文集 D3 (土木計画学) (2020), **75**, **6**, pp. I.127-I.135.

