

深層学習によるため池崩壊に伴う建物被害棟数の推定

ESTIMATION OF THE NUMBER OF DAMAGED BUILDINGS DUE TO RESORVOIR COLLASPE BY DEEP LEARNING

和田 光真¹⁾, 吉田 秀典²⁾

Mitsumasa WADA and Hidenori YOSHIDA

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

The risk of reservoir damages due to heavy rains and huge earthquakes is increasing. The disaster prevention drills using the hazard maps and legislation regarding the management of aging agricultural reservoirs are implemented as disaster prevention. Furthermore, it is necessary to improve the awareness of the residents who lives in the area of flooded estimated. In this study, the estimation method of the number of damaged buildings in the area from the damage prediction distribution map accompanying the collapse of the reservoir. As a research method, deep learning by the CNN(Convolutional Neural Network) is adopted. The learning model is annotated by marking points on buildings in satellite photos. In addition, the accuracy of the calculation results is strengthened by the ResNet as the learning model. As a result of comparing the model after learning with visual observation, the number of buildings could be detected with high accuracy.

Key Words: reservoir, hazard map, deep learning, CNN, ResNet

1. 緒言

豪雨や巨大地震によって農業用ため池が決壊した場合、とりわけその流出先が市街地の場合には、家屋の倒壊によって甚大な被害が生じる⁽¹⁾。2013年に農業用ため池を対象とした一斉点検が実施され、防災上重要とされるため池は、全国で63,722箇所存在することが明らかとなった⁽²⁾。この対応として、ため池の決壊による災害を防止することを目的とした「農業用ため池の管理及び保全に関する法律」が2019年7月1日に施行され、農業用ため池の所有者等による届出の義務付けのほか、特定の規模のため池を防災重点ため池として都道府県が指定することとなった。同法では、補強工事などのハード対策としての管理体制の強化と並行し、地方自治体による「ため池ハザードマップ」を災害時の避難計画に活用する等のソフト対策が盛り込まれている。しかしながら、防災情報がそこに住む地域住民らの理解や避難行動に直結しないことで、実際の災害時においては、危険地域にもかかわらず避難行動を行わなかったり、過去の経験を頼りに避難の要否を独自で判断してしまったりといった課題⁽³⁾もあることから、ソフト対策としての防災情報を簡潔に住民へ伝えることが重要となる。

近年、人工知能による研究が活発化しており、地図の画像を

詳細に分析する研究が進められている(例えば、文献⁽⁴⁾⁽⁵⁾)。こうした研究を防災の分野にも展開させ、深層学習による災害検出(例えば、文献⁽⁶⁾)などの研究が進められている。そこで本研究では、人工知能の一つである深層学習を利用することで、防災計画上有益な情報を空中写真から抽出する方法について検討する。具体的には、空中写真と洪水解析結果であるハザードマップとを重ね合わせ、その浸水地域の中にある建物の数をカウントする。本論文では、建物をカウントすることのみに留めているが、この手法を展開し、洪水解析結果を学習させることで解析を実施しなくとも建物被害分布を空中写真から検知するようなモデルに適用するという発展形を考えている。このように、ハザードマップなどの応用として、被害を受ける前の状態である空中写真から、倒壊に至るような洪水被害を受ける建物を短時間で検知できれば、防災上有益と考える。また、地方における人口減少や技術者の不足等によって、高度な判断を要するため池調査の検証が難しい状況が予測されるが、今後も防災に係る業務は必要不可欠と考える。技術の継承がされないことで引き起こされるヒューマンエラー⁽⁷⁾を人工知能で防止し、適切な判断ができるように研究を積み重ねることは社会的な意義がある。本論文では、2節にて畳み込みニューラルネットワークを用いた学習手法を説明し、3節において、その学習データを利用

して、浸水地域内における建物の被害棟数を推定する。4節のまとめでは、同手法の活用方法と今後の課題について考察する。

2. 計算の概要

2.1. 建物検出のための学習データ

空中写真から自動車の台数を推定する手法⁽⁸⁾⁽⁹⁾を応用し、ため池堤体の崩壊にともない被害を受ける建物棟数を推定する。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。地図データは、国土地理院撮影の空中写真(2007年撮影)が一般公開されており、全国どの地域でも入手可能である。本研究では、入手が容易なデータであっても学習用データとして有用であることも同時に示すこととした。次に、入手した地図の画像から建物検出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、計算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22cmとし、512×512ピクセル(112.64m×112.64m)の大きさの空中写真を切り取った。また、ため池のある地域は、都市部よりは地方都市や山間部にあることが多い。学習用データの空中写真の収集場所は、地方都市およびため池の周辺に限定した。そして、それらの収集した画像の枚数は、学習率が概ね安定する20枚を用意した。これらの空中写真データに対して、勾配屋根をもつ建物(Positiveと定義)を洪水時に倒壊等の被害を受ける可能性が高い建物と位置づけ、目視によって、「点」を追加する(Annotationと定義)。そして、上記Positive以外の構造物(Negativeと定義)として田畑、車、樹木、道路および水路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20枚、Positiveの位置に点のみを追加した画像が20枚、同様にNegativeの位置に点のみを追加した画像が20枚、合計60枚の画像を用意した。Positive画像中にある点の数の合計が81箇所、Negative画像中にある点の数が合計で711箇所となった。空中写真のオリジナル画像に、Positiveの点を重ねて表示したものとNegativeの点を同様にオリジナル画像に重ねて表示したものの3例をFig.1に示す。このように、点を追加した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、低い解像度かつ低コストであっても精度の良い分析が可能となる。

さらに、畳み込みニューラルネットワーク(CNN)⁽¹⁰⁾による画像認識用の学習データを作成する。畳み込みとは、カーネルという小領域のフィルタを用いて元の画像データから特徴を抽出する操作のことで、抽出されたデータは別途作成した小さい領域(特徴マップ)へ畳み込まれる。具体的には、空中写真から切り取った512×512ピクセルの空中写真を96×96ピクセルの小領域に畳み込む操作となる。96×96の大きさは、空中写真において建物が概ね1棟収まるサイズである。空中写真は、複数の色を持つRGB画像のため、特徴マップは3層となる。

2.2. CNNの学習

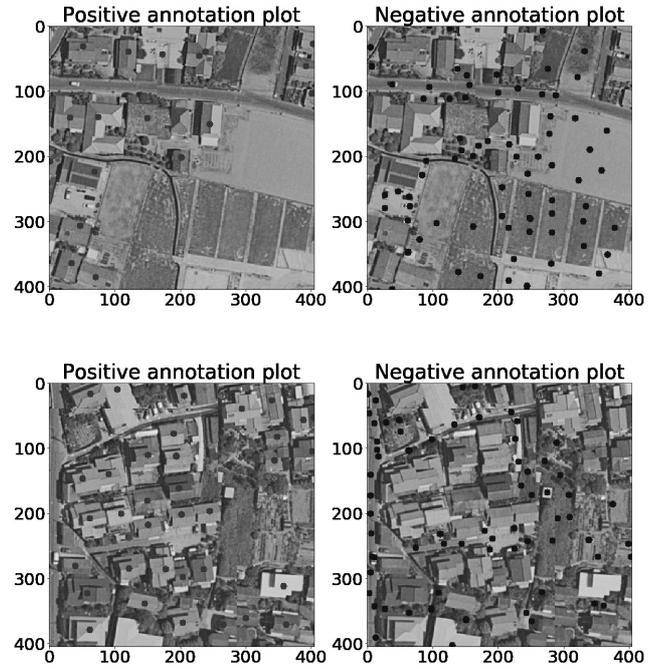


Fig. 1 Annotation plot

CNNの学習には、ResNet(Residual Network)⁽¹¹⁾を利用する。ResNetは、残差の画像が最適となるように残差関数を再構築することで知られている。画像の写像を $H(x)$ とすると、入力画像 x との残差 F は

$$F(x) = H(x) - x \quad (1)$$

となる。上式の右辺第2項 $-x$ を左辺へ移動し、元の写像 $H(x)$ に足し合わせると下式の関係によって写像 $H(x)$ が更新される。

$$H(x) = F(x) + x \quad (2)$$

本研究では、更新される写像 $H(x)$ の最適化を50層繰り返すResNet50を利用した。学習率については、Momentum SGD法⁽¹²⁾を利用した。ここで、SGD法(確率的勾配降下法, stochastic gradient descent)とは、最適なパラメータ θ により目的関数 $J(\theta)$ を最小化することによって、目的関数の勾配方向 $\nabla_{\theta} J(\theta)$ の逆方向にパラメータを更新する手法である。さらに、上記のSGD法に慣性項(Momentum):例えば、U字のレールに沿ってボールが振動する際に振動を抑制する方向に慣性項を追加すること、を加えることで計算の収束時間を短くすることができる。現時点の更新ベクトルを v_t 、過去のタイムステップの更新ベクトルを v_{t-1} とし、 γ を更新時の割合、学習率を η とすると、下式の関係となる。

$$v_t = \gamma v_{t-1} + \eta \nabla_{\theta} J(\theta) \quad (3)$$

学習率 η は、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と設定した。また、文献⁽⁸⁾を参考にして更新ベクトルの割合 γ を0.9とした。学習の手順の概要を以下に示す。

1. 正解のデータと予測値の誤差を計算する
2. 写像の誤差を更新して収束させる
3. 別の検証データと比較する
4. 1.~3. をエポック回数分繰り返す

2.3. 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。本研究では、Fig. 2 に示すように、 512×512 ピクセルの学習用の空中写真を 96×96 ピクセルで分割し、これを 20 枚準備した。同図において、黒色の部分が訓練データ、白色の部分が検証データとなる。訓練データは、学習が進むごとに更新されるデータ、検証データは、元データからの更新はしないデータとなる。本研究で利用した 20 枚の空中写真を全て分割すると、訓練データが 1260 個、検証データが 295 個となった。

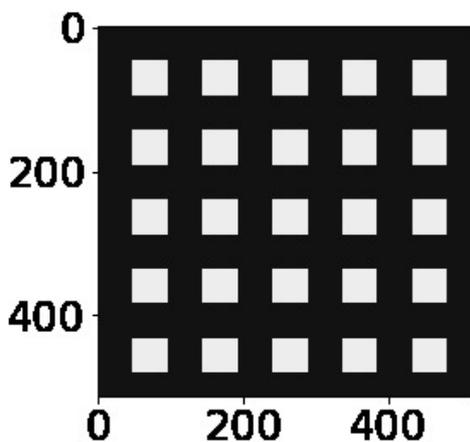


Fig. 2 Training and validation mask

次に、学習の進捗を示すため、学習曲線 (Model accuracy と Model loss) の結果を Fig. 3 および Fig. 4 に示す。ここで、Fig. 3 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 (Training accuracy) と検証データの正解率 (Validation accuracy) 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順調に推移していることに対し、Validation データは 40 エポックあたりから 0.5 付近に収束しており、50 エポックの時点では過学習の可能性があると推定される。

次に、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: Loss と定義) に着目する。Fig. 4 において、損失が小さくなるほど学習が収束していることを示しているが、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。ここでも Fig.

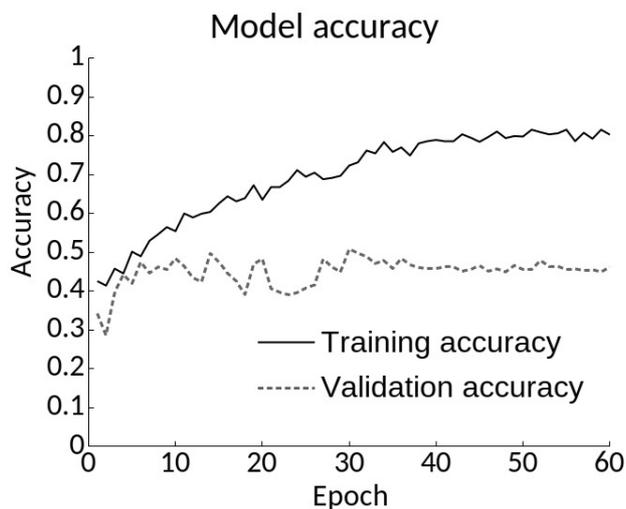


Fig. 3 CNN Model accuracy curves (train and validation) during the 60-epoch training process

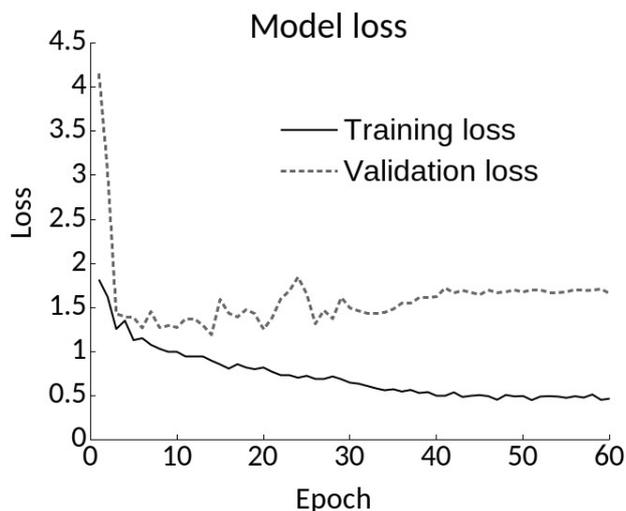


Fig. 4 CNN Model loss curves (train and validation) during the 60-epoch training process

3 と同様に、Training データと Validation データを表示している。Training データは順調に収束するが、Validation データは 30 エポックまでは振動が大きく、40 エポックから収束の傾向が始まり、50 エポックを過ぎると Validation の勾配が反転して増加に転ずる傾向がみられた。このため、50 エポック以降は過学習の可能性があると推定し、本研究では 50 エポック時点の学習済みデータを採用することにした。

次に、CAM(Class Activation Mapping)⁽¹³⁾ により、CNN の学習モデルが建物を正しく認識しているかを確認する。任意の地点において、建物に対して CAM を実施すると、Fig. 5 に示されるとおり、建物の画像における色相が薄くなっている。また、同図右端において、点による画像のアノテーション部分と建物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。

3. 建物被害棟数の推定

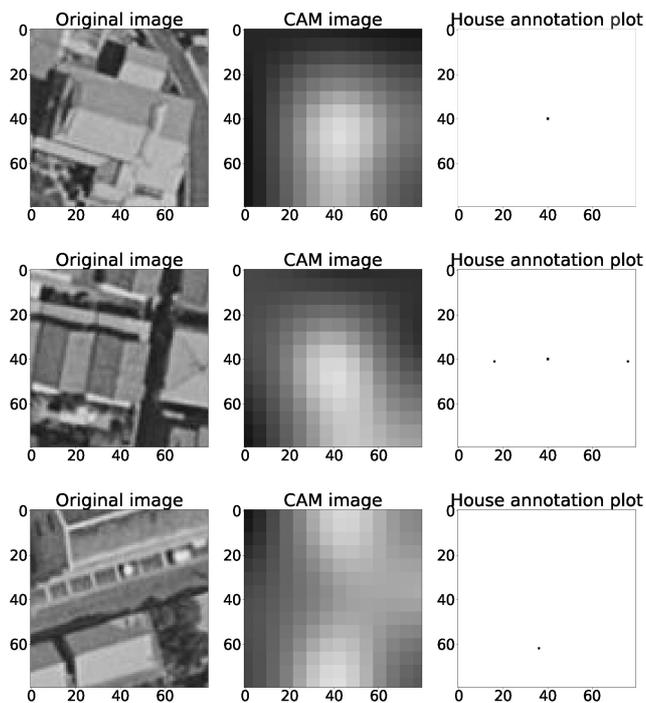


Fig. 5 Correctly classified

3.1. 浸水範囲画像の準備

浸水範囲において建物被害棟数をカウントするため、建物が洪水による被害を受ける範囲を設定する。ため池ハザードマップ作成の手引き⁽¹⁴⁾では、洪水時における木造建物の倒壊および滑動に関する耐力曲線は、流出水の流速と浸水深さの関係が示されており、例えば、浸水深が1.5 mかつ流速が1.5 m/s の状況下では、家屋が倒壊または滑動の被害を受けるとされている。また、「農業用ため池の管理及び保全に関する法律」においても、ため池の規模とため池からの距離によって防災上重要なため池の判定が可能で、大規模なため池の場合、距離500 m以上の浸水区域内に家屋、公共施設等があり、かつ貯水量が5,000 m³以上が防災重点ため池としている。また、筆者らの研究⁽¹⁵⁾において、3次元数値解析の結果とハザードマップとを比較した結果、平面的な浸水範囲の広がりについては概ね一致するものの、ハザードマップは、時々刻々と変化する浸水深および流速までは表現できないことも示している。これらの情報をもとに、本研究においては、平面的な浸水領域については、現時点で自治体により公開されているため池ハザードマップ⁽¹⁶⁾を参照する。また、ハザードマップで示される浸水領域のうち、浸水深と流速が建物の倒壊等に影響すると予想される領域として、浸水深が2 m以上かつため池からの距離が概ね600 mの範囲を簡易的に設定した。Fig. 6において、太線域内を被害予想範囲として示す。なお、被害予想範囲については、洪水解析によって得られる浸水深と流速から示すこともできるが、深層学習用のデータの抽出方法にも関係するため、今後の検討課題としたい。

3.2. 建物検知のための空中写真の準備

空中写真は、学習用データと同様に国土地理院撮影の空中



Fig. 6 Flooded area

写真(2007年撮影)を使用した。建物が被害を受ける浸水予測範囲が十分取まる大きさとし、縦×横:4060×2927ピクセルの空中写真を用意した。なお、空中写真に対して画像処理は実施していない。本研究では、太線で示した領域の内部を建物が倒壊等の被害を受ける領域と仮定し、96×96ピクセルの大きさに分割した領域毎に建物棟数のカウントを実施する。

3.3. 判定結果

深層学習によって被害建物の棟数をカウントした結果をFig. 7に示す。拡大表示の部分に着目すると、建物規模によらず、建物が認識できている。また、浸水部分のカウント数の合計と実際の建物を目視により合計した結果の比較をTable 1に示す。なお、目視の方法については、個人差によりばらつきが予想されるため数人がかりでカウントして平均化して比較している。比較の結果、深層学習による建物数の合計と目視による建物数の合計との一致比率は99%となった。

Table 1 Count comparison of houses

CNN	Visually	Correct ratio
107	108	99 %

次に、深層学習によるカウントの判定について、拡大図によって考察する。空中写真の建物形状とカウント数とを拡大表示したものをFig. 8に示す。ここでは、96×96ピクセル



Fig. 7 The number of houses in flooded area

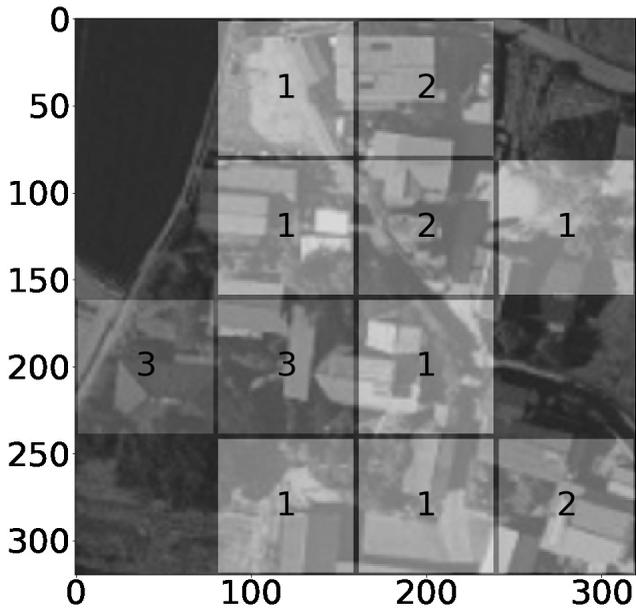


Fig. 8 Enlarged view of 96 pixel division

の大きさに分割した判定領域を透過して表現している。この判定領域の境界内において2つの建物が概ね半分程度重複している場合には、ダブルカウントとなる。一方、建物のごく一部のみがかかる場合においては、カウントされない。そこで、分割セルの大きさによるカウント数の影響を確認するため、分割セルを128×128ピクセルへ拡大した。結果をFig. 9に示す。判定領域が大きくなったことで、領域内のカウント数が増加し、96×96ピクセルのようなダブルカウントの影響は低減された。一方、カウント数が4棟となっている区画領域においてのみ、実際の棟数より1棟分が過大評価となった。これは、庭木と屋根が複雑に重複している状況が学習用データにあまり含まれていなかったことが原因と思われるが、建物の被害棟数の推定を実施するうえでは十分な精度と言える。

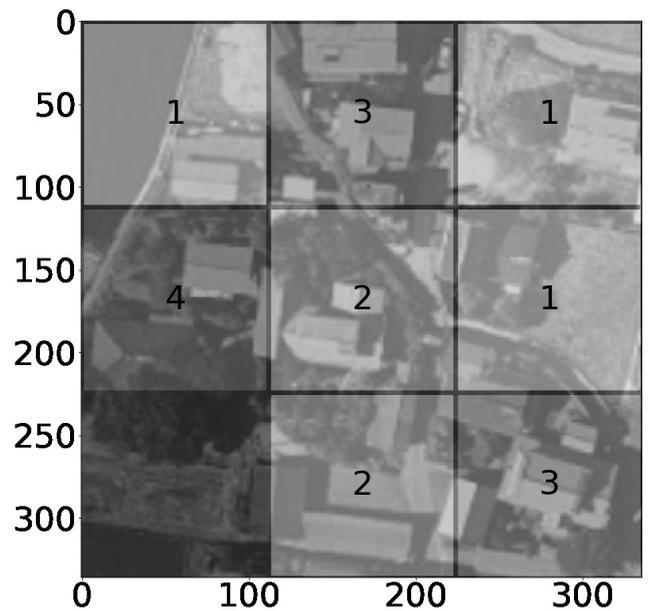


Fig. 9 Enlarged view of 128 pixel division

4. 結言

本研究は、深層学習によってため池被害を受ける建物棟数の推定方法を示した。本研究で訓練したモデルは、下記の条件を満足すれば、空中写真の制限を受けずに適用範囲である。

- 国土地理院の空中写真と同等以上の解像度を有する画像であること (インターネットで無償提供されている空中写真でも可)
- 空中写真の屋根形状が訓練データで使用した画像と大きく乖離しないこと

また、本研究では浸水領域を限定して建物棟数をカウントしたが、より広域な領域において適用することも可能である。実務的には、広い地域で浸水被害が発生した場合、浸水領域が明らかであれば、浸水戸数の概算値を手作業で数えるよりも遙かに短時間で確認できる。また、建物数を表示したセルを災害直後の空中写真に重ねて表示すれば、屋根上まで浸水

して見えなくなった家屋であっても棟数をただちに把握することができる。このように、広域にわたり災害があった場合には、人口知能によって、今まで手作業で行っていた作業をごく短時間のうちに処理することが期待できる。また、災害では様々な状況が想定されるため、学習モデルの汎用性を高めることが重要と考える。本研究の学習モデルは、時間帯による屋根色の違いについては対応可能であるが、水田や山林の季節色および積雪状態の空中写真は、元の訓練データに含まれていないため、判定精度が低下する可能性がある。本モデルの判定結果を防災政策や構造物の計画にそのまま導入することは極めて慎重に検討すべきであり、本研究の学習モデルは、人間による最終判断の参考値としての利用に留めておく必要がある。判定結果の信頼性を高めるためには、さらに多くの訓練データが必要で、今後の検討課題である。将来的には、洪水解析を実施して建物倒壊判定の精度を高め、より高精度な手法を検討する予定である。

参考文献

- (1) 田中忠次, 龍岡文夫, 毛利栄征: 東北地方太平洋沖地震による藤沼湖の決壊原因調査について, ダム工学, Vol.23, No.2, pp.99-114, 2013
- (2) 農林水産省 web ページ「重点ため池の再選定について」: <http://www.maff.go.jp/j/press/nousin/bousai/190611.html>, (2019年9月13日閲覧可)
- (3) 長谷川修一, 加藤真吾, 野々村敦子, 山中 稔: 専門家参加型防災マップの作成と課題, 地盤災害・地盤環境問題論文集, 地盤工学会四国支部, Vol.8, pp.83-90, 2008.6
- (4) R. Hamaguchi and S. Hikosaka : Building Detection from Satellite Imagery using Ensemble of Size-specific Detectors, IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), pp.187-191, 2018
- (5) 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, セッション ID 3P1-NFC-00a-4, p.3P1NFC00a4, 2017
- (6) 植田 大介, 間普 真吾, 呉本 堯, 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, セッション ID 1D1-02, p.1D102, 2018
- (7) NHK ウェブニュース「農業用ため池 約 3000 か所で災害に備えた調査不適切」, 2019年10月9日4時36分:<https://www3.nhk.or.jp/news/html/20191009/k10012118591000.html>, (2019年10月17日閲覧可)
- (8) 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 (ECCV), pp.785-800, 2016
- (9) M. Kimura web ページ Project to train/evaluate convolutional neural networks to count cars from COWC aerial images : https://github.com/motokimura/cowc_car_counting, (2019年9月13日閲覧可)
- (10) S. Ren, K. He, R. Girshick, and J. Sun : Faster R-CNN: Towards real-time object detection with region proposal networks, Advances in neural information processing systems 28, pp.91-99, 2015
- (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 (CVPR), pp.770-778 2016
- (12) N. Qian : On the momentum term in gradient descent learning algorithms, Neural Networks : The Official Journal of the International Neural Network Society, Vol.12(1), pp.145-151, 1999
- (13) 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 (ICCV), pp.618-626, 2016
- (14) 農林水産省農村復興局防災課: ため池ハザードマップ作成の手引き 2013, : http://www.maff.go.jp/j/nousin/bousai/bousai_saigai/b_tameike/pdf/tameike_manual_1rev.pdf (2019年9月13日閲覧可)
- (15) 和田光真, 久保栞, 吉田秀典: ため池損壊にともなう貯留水の流出シミュレーション, 計算数理工学論文集, Vol.17, pp.89-94, 2017
- (16) 高松市 web ページ「高松市ため池ハザードマップ」: <http://www.city.takamatsu.kagawa.jp/sangyou/toti/hazardmap-top.html>, (2019年9月13日閲覧可)