

# 論文 損傷発生時期を考慮した RC 部材の地震ひび割れ画像診断

高橋 賢作\*1・高橋 典之\*2

**要旨**：RC 部材の損傷評価手法として、画像処理手法に機械学習（深層学習）を適用した研究が進められている。当該技術は、地震被害調査の自動化への展開が期待されている。現行の地震被害調査においては、単純にひび割れを検知するだけでなく、地震で新たに発生したひび割れと、従前より存在していた古いひび割れを見分け、新たに生じた地震ひび割れの幅から部材損傷度を評価するなどの対応がとられている。そこで本研究では、発生時期の異なるひび割れに着目し、深層学習による分類が可能であるかを検討した。また、深層学習を適用した画像処理手法（Classification, Segmentation）の地震被害調査への適用限界を考察した。

**キーワード**：鉄筋コンクリート部材、ひび割れ、深層学習、画像分類、領域分割

## 1. はじめに

大地震発生後に安全性の確保、復旧方針の判断、被災者支援などの目的で、建物における地震被害調査が行われる。現行の調査制度<sup>1)</sup>では、資格を持った判定士が全国ブロックごとに担当し、目視によって損傷状態を判断する。しかし、調査の長期化、人手不足などの問題を受けて、機械学習を用いた画像診断を被害調査や危険度評価に活用する試みが進められている。コンクリート構造物に限定しても、ひび割れの検出およびノイズ除去による検出精度の変動を検討した研究<sup>2)</sup>、建築物の劣化状態の判定を行った研究<sup>3)</sup>、ダムや橋梁など水中構造物に教師なし学習の損傷検出を適用させた研究<sup>4)</sup>などが行われており、被害調査の基礎的なデータの提供を可能とすることが期待されている。

通常、専門家による被害調査において対象としている損傷は、**図-1**に示す地震直後の新しい損傷である。一方、**図-2**に示す損傷発生から時間の経過した古い損傷を地震によって生じた損傷と認定することは、適切な調査とはならない。そのため、機械学習において単純にひ



図-1 発生直後のひび割れ画像例（新ひび割れ）



図-2 以前からあるひび割れ画像例（古ひび割れ）

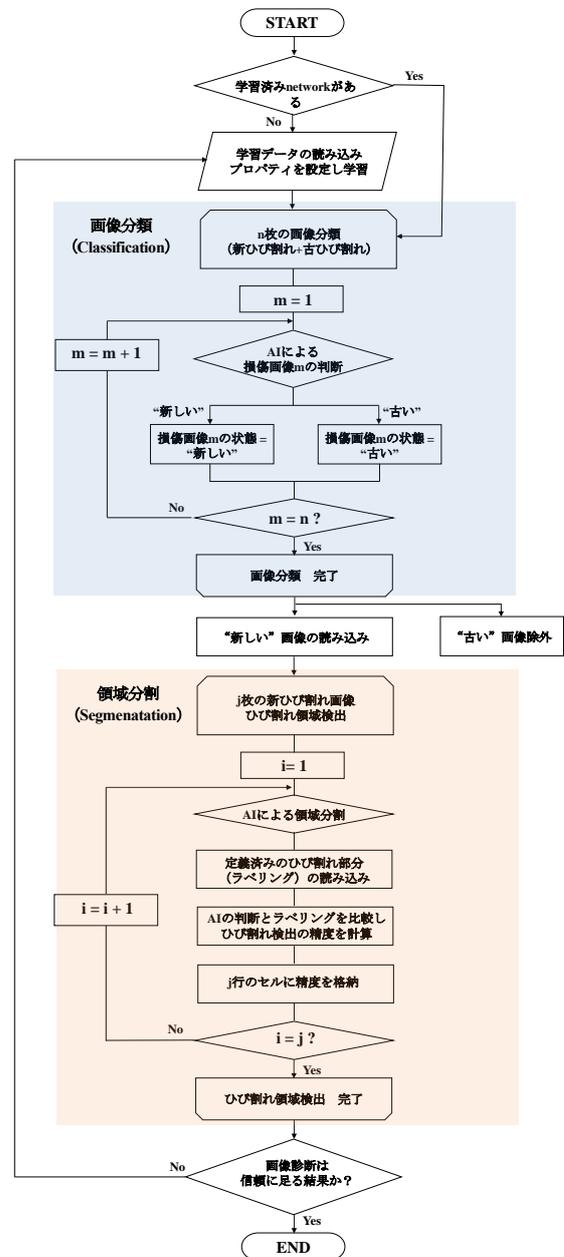


図-3 提案する画像診断フロー

\*1 東北大学大学院 工学研究科 都市・建築学専攻 (学生会員)

\*2 東北大学大学院 工学研究科 都市・建築学専攻 准教授 博(工) (正会員)

び割れ画像を学習させただけでは、地震で新たに発生したひび割れと以前からある古いひび割れとの見分けがつかず、地震損傷を適切に評価することが困難になると考えられる。

そこで本研究では、RC 部材に生じるひび割れに着目し、機械学習を用いた画像診断による地震損傷判定技術に、損傷発生時期の異なるひび割れを分類する画像分類器を導入する手法を提案するとともに、深層学習を適用した画像処理手法 (Classification, Segmentation) の地震被害調査への適用限界を考察した。

## 2. 深層学習による画像診断技術

### 2.1 深層学習の概要

近年の画像処理手法における深層学習は、データから共通する特徴量を学習する、精度の高いパターン認識技術として画像分類 (Classification)、物体検出 (Detection)、領域分割 (Segmentation) の3つの目的で主に活用されている。本研究では、Mathworks 社の Matlab 2020a を用いた Classification, Semantic Segmentation (以下 S-S とする) により、損傷発生時期を考慮した画像診断を行う。本論文で考案した画像診断フローを図-3 に示す。はじめに Classification により、RC 部材に生じた新たなひび割れと古いひび割れの分類を行い、その後 Segmentation を活用してそれぞれのひび割れに対するひび割れ領域検出を行う。また、それらの結果から地震被害調査結果への適用可能性について検討する。

### 2.2 Classification 用の分類器構築

図-4 は Classification の概念図を示したものである。はじめに、学習させたい画像を分類クラス名とともに、教師データとして機械に与える。その後、設定した学習条件に従い、教師データにおける特徴量の抽出が行われ、学習した分類クラス (図-4 の例では Bird か Cat か Human か) を判断する分類器が作成される。最後に、作成した分類器に、評価用の新たな画像を与え、分類クラスのいずれに該当するかを予測する。Classification に関しては、これまでも被災住宅の被害画像から損傷状態のクラスを分類する研究<sup>9)</sup>などが行われており、災害時の定性的な被害の評価に利用できるものと期待されている。

本研究では Classification を、被害調査時に観測すべき新しいひび割れと、調査対象とすべきでない古いひび割れとの分別に用いることとした。深層学習に用いる画像は Training Dataset 中の 8 割とし、学習と並行して過学習になっていないかを検証する Validation Data に残りの 2 割を利用した。学習済みデータセットには ResNet 50<sup>6)</sup>を採用し、初期学習率を 0.0001、学習の反復実施を目的として抽出使用される学習サンプル (サブセット) のデータ数であるミニバッチサイズを 4、学習の反復を 100 回

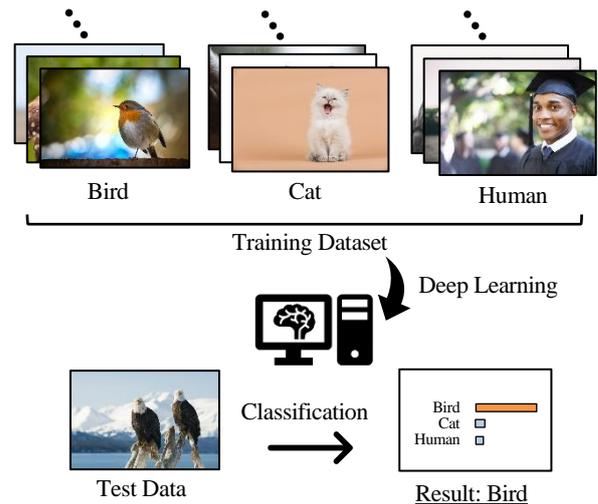


図-4 Classification 概念図

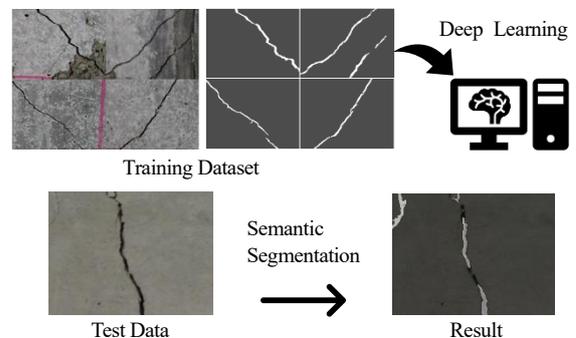


図-5 Semantic Segmentation 概念図

と設定し、最適化手法にはモーメンタム項付き確率的勾配降下法<sup>7)</sup> (SGDM) を用いた。

### 2.3 Semantic Segmentation 用の検出器構築

図-5 は S-S の実施を模式的に表した図である。はじめに、対象画像において学習させたい領域を表すラベリング画像を作成し、元の RGB 画像とラベリング画像を学習のための入力情報とする。その後、両画像の比較により、ラベリング領域における特徴量が学習され、学習した領域と同じ意味を持つ領域 (図-5 中ではひび割れ領域) を判断・抽出する検出器が作成される。最後に、作成した検出器に、評価用の新たな画像を与えると、画像内の検出オブジェクトをピクセル単位で抽出することが可能となる。一般に S-S 技術は大量の学習用データセットを用意するのが難しいが (ラベリングが難しいが)、画像認識技術の中でも詳細な領域までの予測が可能である点が優れており、ひび割れの長さや幅などの損傷を定量的に評価する技術への展開が期待されている。

本論文で S-S の実施に用いるのは Google が提案した Deeplabv3+ネットワークとし、その構造を模式図として図-6 に示す。Deeplabv3+は、空間ピラミッドプーリング (Spatial Pyramid Pooling) を Encoder-Decoder (情報圧縮-情報復元) 構造内に組み込むことで、特徴量を詳細

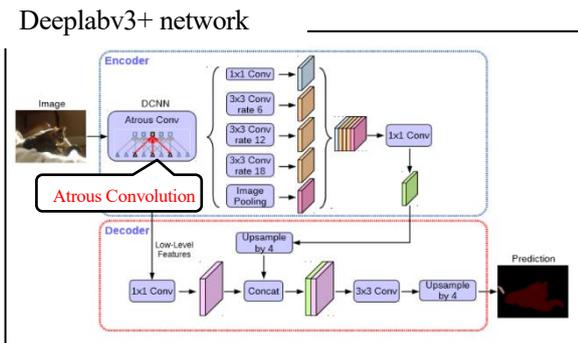
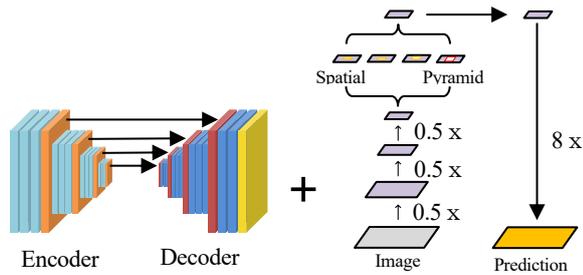


図-6 Deeplabv3+ネットワーク<sup>8) 9)</sup>

にとらえ、出力画像の領域境界を鮮明化できるネットワークである。入力データの特徴量を抽出する Encoder の畳み込み方式に特徴を有し、様々な視野スケールで畳み込む Atrous Convolution (膨張畳み込み) により、畳み込みで得られるテンソル (特徴マップ) が様々な視野スケールを持ち、パラメータ数や計算量を変えずに層の受容量 (層で確認できる入力情報領域) を増やすことができる。本研究では、既往の研究<sup>10)</sup>を参考に、事前学習済みデータを活用して新たなモデルの再構築を行う転移学習による学習データセットの増強を通して、精緻な学習ネットワークを構築した。この際、事前学習済みデータセットには ResNet 50<sup>6)</sup>を採用した。また、学習パラメータについては、初期学習率を 0.01、学習回数を 50 回、ミニバッチサイズを 2 と設定し、最適化手法にはモーメンタム項付き確率的勾配降下法 (SGDM)<sup>7)</sup>を用いた。

### 3. 発生時期の異なるひび割れの画像分類 (classification)

#### 3.1 ひび割れの特徴分析とひび割れ画像の収集

ひび割れ画像の収集 (撮影) を行うにあたり、対象とするひび割れの分類基準を整理する。図-1、図-2 はどちらも地震起因のひび割れであるが、相違点としてひび割れ周辺の状態が挙げられる。地震発生直後のひび割れ (以下「新ひび割れ」とする) はエッジがシャープで、非ひび割れ部との境界が鮮明である一方、発生から時間の経過したひび割れ (以下「古ひび割れ」とする) は、ひび割れ領域境界が曖昧となる。

また、図-7 のように、環境作用により進展する特徴

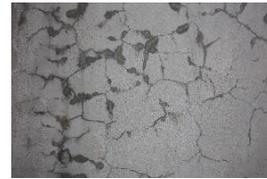


図-7 環境起因の  
亀甲状ひび割れ



図-8 撮影距離  
および照度の測定

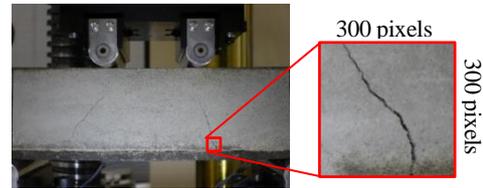


図-9 新規ひび割れの確保

的なひび割れ (例えば亀甲状に進展するひび割れ) については、ひび割れ境界領域に着目せずともその全体的な形状から「古ひび割れ」として判断可能である。なお本研究では、地震被害調査への適用を想定し、ひび割れ進展の全体形状による分類は対象外とした。

すなわち本論文では、「新ひび割れ」を「地震直後に新たに発生し、ひび割れ境界部の明度差が比較的大きいひび割れ」、「古ひび割れ」を「ひび割れ境界部の明度差が小さいひび割れ」と定義し、ひび割れ境界が鮮明か否かを発生時期の判断基準とした。

上述の基準に従い、打ち放し仕上げの RC 壁部材および RC 柱部材を対象として、発生時期から時間が相当経過したと推察される「古ひび割れ」の写真約 240 枚を撮影した。図-8 は、撮影距離および照度を測定しながら撮影を行っている様子である。ここで、既往の研究<sup>11)</sup>に基づき、ひび割れ検出精度を確保するため被写体との撮影距離を 500 mm とし、照度は 100 lx~20000 lx の被写体環境で撮影した。なお撮影画像の RGB 濃度を輝度換算した輝度中央値は (0~255 階調で) 58~138 であった。また、撮影画像の解像度は 8688 pixel×5792 pixel であり、空間分解能は約 0.05 mm/pixel であった。一方、比較対象である「新ひび割れ」については、目的にかなう撮影が実施可能な地震被害が直近で発生しなかったため、図-9 に示す静的載荷実験で観測された RC 造試験体 (柱および梁) のひび割れを「新ひび割れ」として画像データに用いた。以上の新旧 2 種類のひび割れ原画像を、300 pixel×300 pixel に分割し、学習用画像データとした。

#### 3.2 分類器の作成

学習に用いるひび割れ画像を収集した後、使用する ResNet 50<sup>6)</sup>の指定画像サイズである 224 pixel×224 pixel への再分割を行った。その際、切り出し画像から発生時期が目視により判断できるかを前述した分類基準をもとに再検討し、使用する画像を選別し直した。分類器の作成

にあたり、「新ひび割れ」のみで構成される 100 枚のデータセットを 2 つ、「古ひび割れ」のみで構成される 100 枚のデータセットを 2 つ、それぞれ作成した。その後、データセットごとの組み合わせ  $2 \times 2 = 4$  通りのパターンについて深層学習を行い、学習に使用していないデータセットを対象に画像分類を適用した。各学習による各分類器の作成、および、各データセットに対する各画像分類器の組み合わせ一覧を図-10 に示す。

### 3.3 分類結果

各分類器における分類結果を図-11, 図-12, 図-13, 図-14 にそれぞれ示す。図中の青色は正解, 赤色は不正解を表している。また、色の濃さは数字の大きさ（正解および不正解の割合）を反映している。

「古ひび割れ」については 4 通りの分類器全てで良好な分類結果が見られた。中でも分類器 1~3 では、正答率 99%以上の結果となった。これより、「古ひび割れ」に対して 3.1 節で定めた分類基準（ひび割れ領域境界状態）を深層学習により評価可能であることがわかった。また、

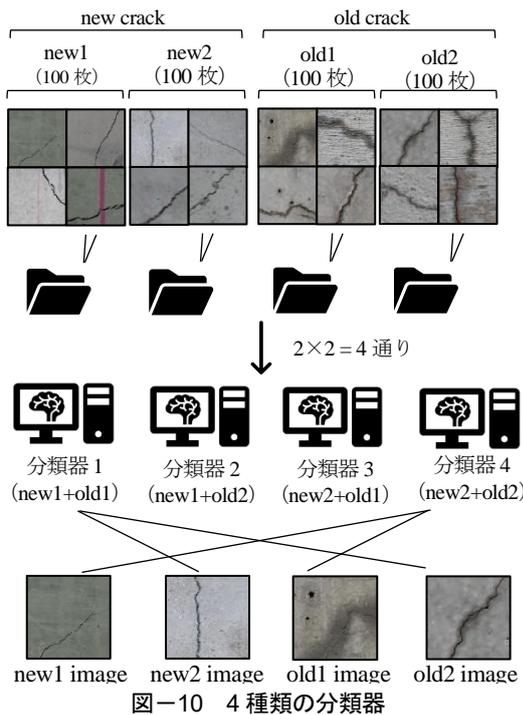


図-10 4 種類の分類器

真のクラス "old"	"new"	53	47
	"old"	1	99
		"new"	"old"
		予想されたクラス	

図-11 分類器 1 (学習: new1+old1) の分類結果

真のクラス "old"	"new"	69	31
	"old"	0	100
		"new"	"old"
		予想されたクラス	

図-12 分類器 2 (学習: new1+old2) の分類結果

真のクラス "old"	"new"	96	4
	"old"	0	100
		"new"	"old"
		予想されたクラス	

図-13 分類器 3 (学習: new2+old1) の分類結果

真のクラス "old"	"new"	99	1
	"old"	8	92
		"new"	"old"
		予想されたクラス	

図-14 分類器 4 (1 学習: new2+old2) の分類結果

データセットの撮影環境は様々であり、ひび割れ領域のエッジに関する特徴を除いて、それぞれ異なる特徴を有するひび割れ画像が各データセットに含まれているにも関わらず、比較的正確な分類ができていることから、本研究で用いた学習パラメータで過学習することなく、適切に学習が行われたといえる。

一方、「新ひび割れ」については、学習用データセットによって対照的な精度となった。学習用データセットが new2 (分類器 3, 4) の場合は正答率 96%以上となり、鮮明なひび割れ境界を有する特徴を抽出できているが、学習用のデータセットが new1 (分類器 1, 2) の場合は正答率 70%未満となった。ここでデータセットを細かく分析すると、学習用データセット new1 の画像群は、データセット new2 の画像群に比べ、背景部分の汚れや凹凸が少なく、きれいな躯体面に生じたエッジの鮮明なひび割れ画像が多く含まれていた。データセット new1 と「古ひび割れ」(データセット old1 または old2) を組み合わせると、ひび割れ境界 (エッジ) の差異ではなく、背景 (ひび割れ領域以外) の汚れの有無を分類器が重視するようになったと考えられる。これを高い正答率とするには、背景部分の汚れの有無が同程度の画像群 (例えば、データセット new2 と「古ひび割れ」の組み合わせ) を学習用データセットの組み合わせとして用いることで、分類器で着目して欲しい箇所が、背景部分の汚れの有無ではなく、ひび割れ境界 (エッジ) 状態の差異になると予想される。今後、学習において重視した領域を数値化して明示する Grad-CAM を利用して、実際に分類器が判断した基準について検討を行う予定である。

以上より、classification 技術はひび割れ発生時期の新旧を判断するにあたり、特に「古ひび割れ」に対して一定の分類精度があるといえる。すなわち、地震被害調査で評価対象にならない「古ひび割れ」を事前に取り除くプリプロセスとして、classification 技術を利用することが可能と考えられる。

### 4. 領域分割 (segmentation) によるひび割れ領域検出

3 章の結果より、地震被害調査の対象外となる「古ひ

び割れ」画像を、classificationにより分別できることが確認された。本章では、S-Sによるひび割れ領域検出を適用し、発生時期の異なるひび割れの領域抽出に対する精度の差異について考察するとともに、「古ひび割れ」をプロセスとして除去することの有用性を検証する。

#### 4.1 ひび割れ検出における精度

S-Sによる検出精度を算出する上で、S-Sの出力画像は正解データであるラベリング画像をもとに4つの論理領域に分けられる。各論理領域のピクセル数をもとにS-Sの検出精度が評価され、その指標は一般にAccuracyやIntersection over Union（以下IoUとする）が用いられる。AccuracyおよびIoUは、それぞれ、式(1)、式(2)で定義され、対象とする領域をどの程度正確に検出できているかを0~1の値で表したものである。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (2)$$

ここにTP:正確に検出できたピクセル数, TN:正確に検出をしなかったピクセル数, FP:誤検出したピクセル数, FN:検出漏れしたピクセル数である。

図-15は、ひび割れ領域の検出結果およびその検出精度の算出例である。Accuracyについては、式(1)よりTNが大きくなるほどAccuracy値も大きくなる傾向にあるといえる。そのため、ひび割れのような対象画素内に占める割合が比較的小さなものを対象とする場合、図-15のように検出がほとんどできていないにも関わらずAccuracyは大きくなる例が往々にして見られる。一方、IoUは、その値がTNに依存せず、画像の大部分を占める背景部分の認識を考慮しないため、検出の正確さにおいてAccuracyよりも厳密な評価が可能といえる。

そこで本研究では、検出精度を表す指標としてIoUを採用し、発生時期の異なるひび割れに対してS-Sの検出性能がどのように変化するかについて検討を行った。以後、IoU値を単に「精度」として扱うことにする。

#### 4.2 検出器の作成

3章と同様に、「新ひび割れ」100枚のデータセットを2つ、「古ひび割れ」100枚のデータセットを2つ設定し、それぞれに対応するラベリング画像を作成し、深層学習により4種類の検出器を作成した。ここで、学習に使用していないデータセットを対象にS-Sを適用することとした。作成した4種類の検出器一覧を図-16に示す。なお画像サイズはそれぞれ300 pixel×300 pixelとした。

#### 4.3 ひび割れ領域検出結果

4種類の検出器における検出結果を図-17、図-18、図-19、図-20にそれぞれ示す。データセットに対応す

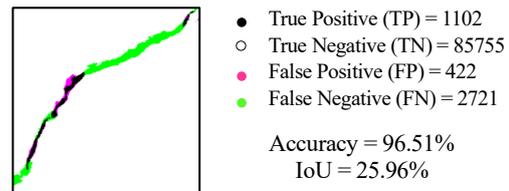


図-15 ひび割れ検出精度の算出例

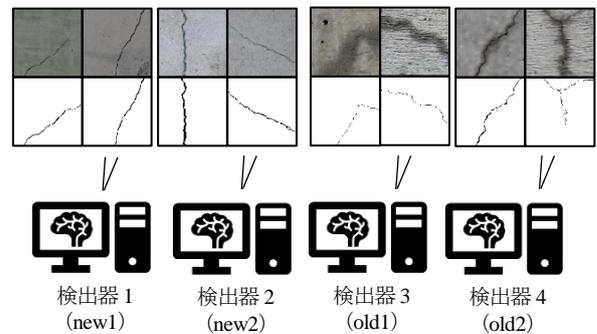


図-16 4種類の検出器

る色は各図共通で、IoUの平均値を図中に示している。

「新ひび割れ」のみを学習した検出器1, 2についての検出結果では、学習していない「古ひび割れ」の検出精度が低くなった。精度の平均値を見ても、新旧のひび割れで約20~30%の差があった。この原因として、評価用に与えた「古ひび割れ」画像の背景の汚れや空隙をひび割れと誤認したことや、ひび割れと背景の輝度(色の度合)が近いために正しくひび割れ領域を認識できなかったことが考えられる。一方、評価用に「新ひび割れ」画像を与えた場合は、「新ひび割れ」のひび割れ境界部の明度差が大きく、ひび割れ領域抽出が「古ひび割れ」よりも容易なため良好な検出結果となった。ただし、黒い躯体にひび割れが生じた場合など、背景画像からひび割れ領域を判別することが難しい場合には、領域抽出が困難になることが予想される。

一方、「古ひび割れ」のみを学習した検出器3, 4では、評価用に与えた「新ひび割れ」画像でのひび割れ領域検出精度は低くなることなく、検出器1, 2と同程度の検出精度が見られた。これは背景ノイズに対する学習が検出器1, 2よりも十分に行われたことで誤検出を回避し、IoUが向上したものと考えられる。一方、評価用に与えた「古ひび割れ」画像に対しては、「古ひび割れ」を対象に学習したにも関わらず、低精度の検出結果となった。これは、検出器1, 2同様の理由で、ひび割れ領域と背景画像の輝度が近いケースで検出漏れをしたためと考えられる。以上より、「新ひび割れ」と「古ひび割れ」いずれの検出器であっても、評価用画像の「古ひび割れ」はS-Sによって領域抽出するのが困難であり、検出精度が低くなる傾向が確認された。このことから「古ひび割れ」と「新ひび割れ」を区別せずに領域検出を行っても、低

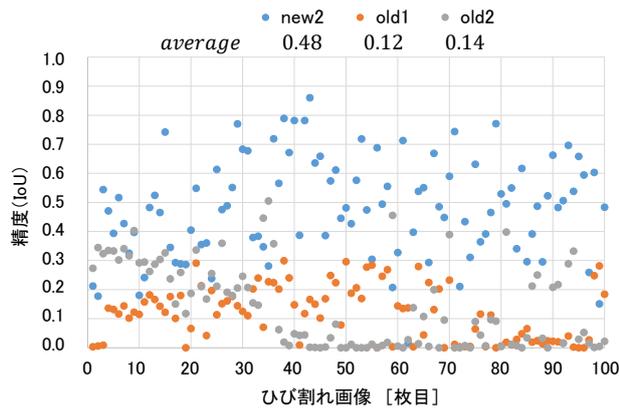


図-17 検出器 1 の検出結果

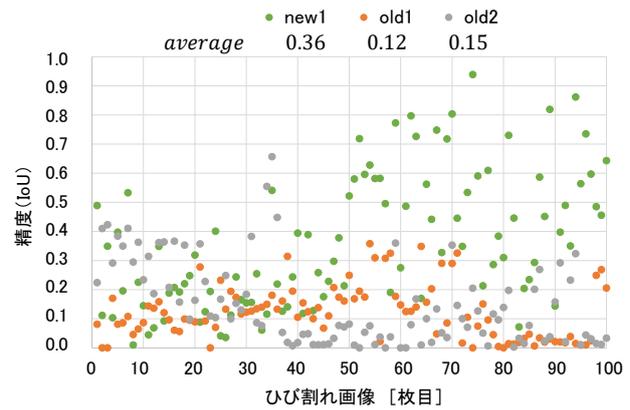


図-18 検出器 2 の検出結果

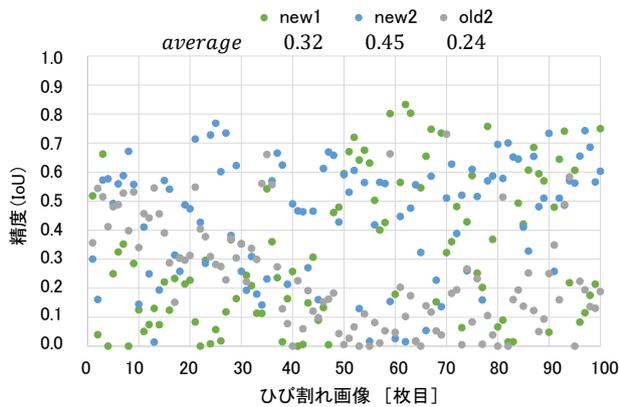


図-19 検出器 3 の検出結果

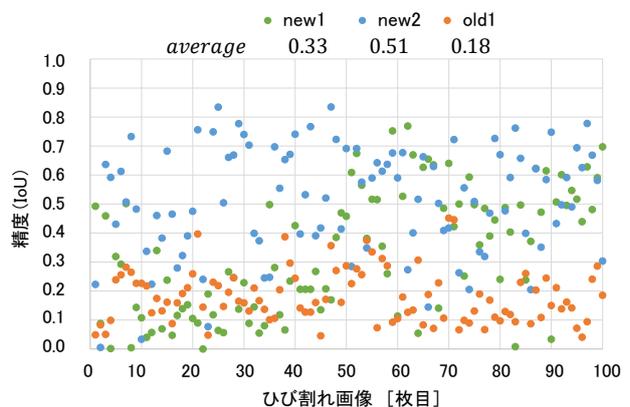


図-20 検出器 4 の検出結果

精度の検出結果しか得られず、適切な画像診断とはならないことが分かった。したがって、S-S による領域検出においては、「古ひび割れ」を除去して「新ひび割れ」と区別できるように、あらかじめ分類しておく必要がある。すなわち、地震ひび割れに対する画像診断において、3章で示した「古ひび割れ」を classification 工程で事前に除去するプリプロセスが有用であると示唆される。

## 5. まとめ

本研究で得られた知見を以下にまとめる。

- 1) 発生時期の異なるひび割れ画像分類 (Classification) を行った結果、「古ひび割れ」を90%以上の正答率で分類できた。
- 2) S-S によるひび割れ領域検出を行った結果、「古ひび割れ」の検出精度は低く、Classification によるひび割れ画像の事前選別が、地震ひび割れに対する画像診断において有効と考えられる。

## 参考文献

- 1) 日本建築防災協会：震災建築物の被災度区分判定基準および復旧技術指針，2015
- 2) 山根達郎，全邦釘：Deep learning による Semantic Segmentation を用いたコンクリート表面ひび割れの検出，構造工学論文集 Vol.65A，pp.130-138，2019

- 3) H.Perez, J.H.M.Tah, A.Mosavi : Deep Learning for Detecting Building Defects Using Convolutional Neural Networks, 2019
- 4) L.Mucolli, S.Krupinski, F.Maurelli, S.A.Mehdi, S.Mazhar : Detecting cracks in underwater concrete structures : an unsupervised learning approach based on local feature clustering, 2019
- 5) 上岡洋平, 田中聡 : 深層学習による建物被災写真を用いた建物被害判別モデルの検討, 日本建築学会大会学術講演梗概集, 2018
- 6) He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun: Deep residual learning for image recognition, In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778. 2016
- 7) Ning Qian: On the momentum term in gradient descent learning algorithms. Neural networks, the official journal of the International Neural Network Society, No.12(1), pp. 145-151, 1999
- 8) 原田達也：画像認識，講談社，2017.5
- 9) Google Inc : Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, 2018.8 (<https://arxiv.org/pdf/1802.02611.pdf>)
- 10) 千田紘之, 高橋典之 : 深層学習を用いたコンクリート基礎および外装材の画像診断, コンクリート工学年次論文集 Vol.41, No.2, pp.1315-1320, 2019
- 11) 高橋賢作, 高橋典之, 千田紘之 : RC 部材の地震損傷画像計測のための撮影環境に関する考察, コンクリート工学年次論文集 Vol.42, No.2, pp.889-894, 2020