

論文 人工知能を用いたモルタル系建築外装材の損傷画像診断と危険度判定に関する研究

千田 紘之*1・高橋 典之*2

要旨： 広範囲かつ多数の余震による各種被災判定の長期化を受け、迅速に判定する技術やシステムの開発が行われている。今後南海トラフ地震や首都直下型地震が発生することが予想されており、より甚大な被害かつ判定の長期化が見込まれており、より迅速な判定が要求されている。近年、建築物への人工知能による画像診断に関する基礎的研究が行われているが、いずれも建物の局所的あるいは全体的な見た目の損傷による評価にとどまっている。そこで本研究では、人工知能を用いて地震による被災戸建て住宅のモルタル系外装材を対象に画像診断を行い、被害の検出とその評価について検討を行った。

キーワード： モルタル外装材, 損傷, 人工知能, 木造住宅

1. はじめに

広範囲の地震や頻繁な強い余震に伴い、被災建築物応急危険度判定や被災度区分判定、罹災証明などが長期化する傾向にあり、人海戦術に限界があることが認知されるようになり、近年ではこれらの工程の迅速化に関する研究や自治体の体制の強化などが行われている。2016年に発生した熊本地震では、最大マグニチュード 7.3 の地震と度重なる余震で建築物の被害は甚大となり、応急危険度判定にかかった期間が 1 ヶ月半と長期化し、後の罹災証明の発行、地震保険の支給も遅延化した。これにより避難生活の長期化や判定前の住宅進入により 2 次災害で死者が出るなどの問題が発生したため、より迅速な被災判定が求められている。

このような状況にあって、近年トンネル内壁や橋梁のひび割れ損傷量評価に人工知能による画像診断を使った研究や実例が増えており、海外では主に被災建築物の損傷量評価に応用されている研究もある¹⁾。そこで、本研究では人工知能、特にディープラーニングを用いた物体検出および領域分割によってモルタル外装材を有する被災住宅の画像診断を行い危険度判定等の有用な情報の提供を試みる。

2. 画像診断と被災度判定

画像診断を取り入れた被災度判定は人海戦術が人工知能に取って代わることで迅速化する(図-1)。本論文で




図-1 地震発生後の流れ

は、新しい技術を応急危険度判定及び地震保険損害査定に適用することを念頭に検討を進める。

まず、図-2のように応急危険度判定を参考に、一見して危険な写真を人工知能により選別し、選別されなかった画像から詳細判定における被害の検出を行い、小被害、中被害、大被害をそれぞれランク A～C で分類を試みる。本研究では特にモルタル仕上げの壁の被害を対象に議論を進める。検出においては、検出面積ないしはそれに相当するものを算出することで、地震損害査定における損害率の算定への展開を検討する²⁾。

3. 機械学習の概要

3.1 分類器の決定

機械学習には、Math Works 社の MATLAB を用いた。




図-2 人工知能による画像診断フロー

*1 東北大学 工学部建築・社会環境工学科（学生会員）

*2 東北大学大学院 工学研究科 准教授 博(工)（正会員）

物体検出や分類用のための機械学習の手法は非常に多岐にわたるが、本章では Cascade Object Detector（以下 Cascade とする）、R-CNN(Regions with Convolutional Neural Networks) Object Detector（以下 R-CNN とする）、Semantic Segmentation（以下 SS とする）について簡単に説明する。

(1) Cascade Object Detector

Cascade は縦横比のあまり変化しない顔や標識、特定方向から見た車などの物体の検出に向いている。そのため住宅の地表被害位の検出には向いていない。

(2) R-CNN Object Detector

一方、R-CNN では、図-3 に示した入力層 (Image Input Layer)、2 次元畳み込み層 (Convolutinal 2D Layer)、活性化層 (RELU Layer)、最大プーリング層 (Max Pooling Layer)、全結合層 (Fully Connected Layer)、活性化層 (Softmax Layer)、分類層 (Classification Layer) から構成される畳み込みニューラルネットワーク (CNN) を用い、より大規模かつ様々なイメージを使用することで豊富な特徴表現を学習し、Cascade の分類器よりも高精度で分類することができる。学習のために入力層に入力する元画像から Region of Interest（以下 ROI とする）と呼ばれる元画像の中の関心のある領域についてラベリングを施したもの（図-4）を作成、使用する。これにより、ラベリングを施した領域のみに対して計算を行うため、従来の元画像を複数分割してすべての領域を解析する手法よりも解析時間を短縮することができる。

(3) Semantic Segmentation

以上の機械学習手法のほかに、SS がある。SS は、Cascade や R-CNN のような物体の検出ではなく、画像内

表-1 検討条件およびパラメータ

分類器	検討条件	パラメータ
R-CNN	学習画像（枚）	30,000+180
	学習反復回数（epoch）	100
	レイヤー（層）	15
SS	学習画像（枚）	50
	学習反復回数（epoch）	100
	レイヤー（層）	10

のピクセルがどの領域に属しているのかを推定し、分類する手法であり、ROI によりラベリングされたピクセルをもとに機械学習を行う。物体検出よりも複雑な処理のため、近年情報系の分野で盛んに研究開発が行われており、今後の発展が期待される学習法である。

本研究では、地震被災建築物という複雑かつ様々な形をとり得るオブジェクトを扱うため、R-CNN と SS を併用する。

3.3 学習用画像の選定

機械学習には、レイヤーや学習アルゴリズムなどの定義、学習用データセットの用意などが必要である。本研究ではモルタル外装材が剥離し、下地板が露出した部分を検出、分類できるように 2016 年熊本地震までの 30 の被害地震における関連資料や被災写真 30,000 枚以上を収集した。図-5 に学習用データセットの一例を示すが、本論文で機械学習に使用した写真は示した収集した写真のうち 200 枚程度である。通常、学習には何千何万もの画像を必要とするが、本論文では図-6 に示す




図-3 畳み込みニューラルネットワーク (CNN)



図-4 ROI によるラベリング



図-5 学習用データセット例



図-6 Cifar10Net³⁾

Cifar10Net³⁾画像データセット 30,000 枚を使用し事前学習を行った後、用意したデータセットで転移学習を行った。これにより、Cifar10Net のデータセットを用いて学習用の特徴量を抽出する分類器を作成した後に、少ない枚数のデータセットで分類器を微調整することでも被害検出用の分類器を構築することができる。なお既往の研究⁴⁾では、転移学習にひび割れ画像を用いる場合、150 枚以上の学習で概ね良好に損傷を検出できたことが報告されており、本研究ではこれを参考に 200 枚程度とした。

3.4 検討条件およびパラメータ

前項の学習用画像の選定と併せて、表-1 のように学習用パラメータを設定した。R-CNN ではCifar10Net による学習枚数の増量を行っているが、SS では事前学習用のデータセットを用いておらず、200 枚としている。

4. 解析結果と評価

前章の条件およびパラメータにより、R-CNNおよびSSを用いて解析を行った結果とその評価について記述する。

(1) R-CNN Object Detector

R-CNN により住宅全体の画像を解析すると、図-7 のように被害箇所だけでなく窓やフェンスなどの様々な箇所を検出した。これはモルタル外装材剥落部の下地材を学習しているため、ルーバー窓や下地材と似た色のフェンスの錆を誤検出しているのだと考えられる。

ここで、IoU (Intersection over union) という物体検出の分野で使われる評価指標を用いて解析結果を評価する。IoU とは、事前にラベリングしていた領域のうち検出さ

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

れた部分を TP (True positive)、検出されなかった部分を FN (False Negative)、検出されたがラベリングしていなかった部分を FP (False Positive) として、式(1)で定義され、1 に近いほど解析精度が高いことを意味する (図-8)。学習させたい領域をどの程度正確に検出できているのか評価することができ、今回解析を行った画像の IoU を表-2 に示す。表-2 は検出結果の確からしさスコアが 0.9 以上の結果を用いて計算しているが、IoU が 0.037 という結果となった。なお、確からしさスコアは 1 に近いほどデータセットに似たデータであることを示す指標

表-2 IoU R-CNN

	ピクセル面積 (pixel×pixel)
TP	135683
FP	3212690
FN	354275
IoU	0.037

で、IoU とは異なりラベリング領域の大小は影響しない。

(2) Semantic Segmentation

次に図-9 のように ROI のラベリングを施し、住宅全体画像での SS の解析を行った。図-10 の結果から、R-CNN と同様ノイズ誤検知が多く、IoU は 0.020 となった。これらの結果から、機械学習において最も重要な学習用のデータセットの改良を以下に検討する。

4.1 データセットの改良

(1) データセットの作成

学習用の画像の縦横を 300×400pixel に統一し、図-11 のようにクロマキー合成を施す。実際の被災写真から



図-7 住宅画像全体による R-CNN 解析




図-8 Intersection over union




図-9 ラベリング (左) と検出結果 (右)



図-10 住宅画像全体による SS 解析

被害箇所のみ切り抜き、無被害の住宅写真に後付けとして上から張り付けたものがクロマキー合成画像であり、これらをデータセットとした。従来のデータセットを大量に作成し検出する研究では、固有の看板や標識など普遍性があるものに対して用いられており、住宅被害などの普遍性のないものについての適用例は殆どない。

(2) Data Augmentation

Data Augmentation は、図-11 のように元画像を左右、上下反転や明暗、色調の変化などの画像加工によりデータセットを増量する手法である。本研究では、作成した20枚のデータセットを200枚に増量した。

4.2 改良後の解析結果

前項で述べたデータセットの見直しと改良、増量を行った結果、R-CNN は図-12 のように、SS は図-13 に、それぞれの IoU は表-3 に示す結果となった。ここで図-14 は図-13 の SS の結果を 0.5~1.0 で確からしスコア（以下、スコア）別に色づけしたものであり、青色ほどスコアが低く、黄色ほどスコアが高い。

結果として、R-CNN については大幅な精度の向上は見られなかったが、SS に関しては図-10 と図-13 の比較からノイズをかなり減らすことができ、IoU が9倍近くなった（表-3）。すなわち、SS においてはデータセットの作成、データの増量が有効であることが分かった。また図-14 からスコア 0.9 以上で図左下の被害箇所を概ね検出できることが確認された。ここで IoU=0.182 の値の評価について、図-8 および式 (1) の定義より検出する対象が画像領域内で小さいほどノイズ誤検出の相対的な影響で値が小さくなる指標であることと、図-14 に示す IoU=0.2 程度で被害の概形が十分形づくられることから、本研究で必要な解析精度を保有していると判断した。

5. 画像診断フローの検証

改良 SS を用いて被害の少ないものと大きすぎるものを解析したところ図-15 のように、ランク A およびラ



図-11 データセットの作成




図-12 改良後 R-CNN 解析



図-13 改良後 SS 解析




図-14 改良後 SS のスコア表示




図-15 ランク A およびランク C 相当の被害

表-3 データ改良後の解析結果

分類器	IoU
R-CNN	0.035
改良 R-CNN	0.036
SS	0.020
改良 SS	0.182

ランク C 相当の壁の被害は高スコアで検出せず、図-13 に示すランク B 相当の被害にのみ高スコアで反応した。これはデータセットに用いた被害が、一見して大規模被害となるランク C や一見すると健全なランク A を除く、ランク B のみであることが反映された結果である。

ここで、R-CNN のみ、あるいは SS のみの結果でスコアを限定して検出した際に含まれる誤検知を、さらに低減するため、R-CNN、SS の両方においてスコア 0.9 以上の結果を統合し、元画像に矩形検出を重ねると、図-18 のように概ね正しい損傷の位置の検知ができた。

以上より、ひび割れ被害の検出（図-16）や、一見して危険なものの除外（図-17）が可能であることが確認され、図-18 のように SS と R-CNN によりモルタル外装材の剥離やひび割れの被害（ランク B の被害）を画像

から抽出・検出する一連の技術の実現可能性を明らかにすることができた。既往の研究 7)における木造建物の詳細破壊パターンと対応する Damage Index およびその詳細な被害（表-4）を、本研究における手法で図-20 のようにひび割れや剥離、倒壊などの限られた範囲にはなるが、検出できるようになった。ただし、より精度良く分類するためには、データセットの見直しや、撮影方法についての検討が必要になると考えられる。これまでも外装材付き構造実験において、表面に現れる見た目の損傷と、構造躯体との関係についての検討が数多くなされており、このような関係性について、信頼性の強いデータベースを介在させることで、表-5 のように外装材の被害から不可視な構造躯体の層間変形角や応答加速度などの工学的指標との関係を推定し、被害の数値化、分類




図-16 ひび割れの検出




図-17 倒壊建物の検出




図-18 検出結果の統合

表－4 木造建物の詳細破壊パターン⁵⁾

Damage Index	応急危険度判定	木造建物の詳細破壊パターン						Damaged Wall	Crack	Dangerous
0.0	安全							—	—	
0.1										
0.2										
0.3										
0.4	要注意							✓	✓	—
0.5										
0.6										
0.7	危険							—	—	✓
0.8										
0.9										
1.0										

表－5 層間変形角と被害の関係性⁶⁾

被災建築物応急危険度判定		Aランク				Bランク			Cランク
被災度区分判定		軽微			小破	中破	大破		倒壊
推定される最大変形角		1/450	1/300	1/200	1/120	1/60	1/45	1/30	1/20超
残留変形		木造軸組工法 (金物耐力壁)	1/1900	1/1000	1/600	1/300	1/120	1/60	1/40
外装材	サイディング張り (縦張り)	—	—	—	釘の浮き	開口部隅角部に割れ	開口部隅角部の割れ拡大 一部に浮きがみられる	開口部隅角部の割れが上下 に通るものがある	外壁平一般部分に割れ複数
	サイディング張り (横張り)	—	—	—	開口部目地部のズレ、止水材の露出 シーリングの局所的な切れ		開口部目地部のズレ、止水材の露出過大 シーリングの大部分の切れ		
	モルタル張り	開口部隅角部に微小の割れ		開口部隅角部に割れ	開口部隅角部の割れ拡大	開口部隅角部以外にも 割れ	開口部隅角部以外の割れ拡大	外壁平一般部分に割れ	外壁平一般部分に割れ複数
	開口部等	—	—	—	サッシガスケットに 部分的外れ	サッシガスケット外れ	サッシのクレセントが 損傷	サッシのクレセントが 破壊、ガラス破壊	サッシのクレセントが 破壊、ガラス破壊複数

が可能になると考えられる。なお、本研究で対象としていないサイディングなど、表面に現れる損傷が構造躯体の損傷の進展に比べて小さく判別しにくい外装材の場合は、検出すべき損傷部位の精査と検証が今後必要になる。

6. まとめ

本論文では、被災判定の迅速化のため画像診断による被害箇所の検出について、R-CNN および SS による解析を行うことで、どの程度被害の検出ができるのか検討を行い、以下の知見を得た。

- 通常、学習データセットには学習に向いているビッグデータが必要となるが、学習データとして撮影されているわけではない従来の実被害写真のみでは学習に向いている写真を収集するのは困難である。しかし、画像加工によりデータセットを作成することで、実被害写真をデータセットとした場合よりも検出精度が高くなることが確認された。
- 本研究では検討対象をモルタル外装材の被害に限定したが、ひび割れや剥離などの地震被害を人工知能により検出・分類できることが確認された。

参考文献

- Karoon Rashedi Nia : Automatic Building Damage Assessment using Deep Learning and Ground-Level Image Data , SIMON FRASER UNIVERSITY (SFU), Oct., 2015
- 社団法人 日本損害保険協会：地震保険損害査定指針，社団法人 日本損害保険協会，pp.17-36，2010.1
- Alex Krizhevsky : The CIFAR-10 dataset, <http://www.cs.toronto.edu/~kriz/cifar.html> (2017.12.5)
- 佐藤真俊，高橋典之，櫻井真人，相澤直之：深層学習を用いた画像計測手法による RC 部材の地震損傷評価，日本コンクリート工学会年次論文集，Vol.39，No.2，pp.739－744，2017.7
- 岡田成幸，高井伸雄：地震被害調査のための建物分類と破壊パターン，日本建築学会構造系論文集，第 524 号，pp.65－72，1999.10
- 国土交通省国土技術政策総合研究所：震災被災建築物の被災度区分判定基準および復旧技術指針 2015 年改訂版，日本建築防災協会，pp.IV-15，2016.3