

1) - 1.1 深層学習と機械学習を活用した建築物損傷評価に関する 研究【安全・安心】

Study on Building Damage Evaluation Utilizing Deep Learning and Machine Learning

(研究開発期間 令和元～3年度)

構造研究グループ
Dept. of Structural Engineering

森田高市
MORITA Koichi

長谷川隆
Hasegawa Takashi

奥田泰雄
OKUDA Yasuo

As image classification method of damage level after earthquake, deep learning with convolutional neural network is applied to building members like reinforced concrete columns. We achieve a classification accuracy of 70% to 85%. The damage state classification method based on machine learning is applied to a shaking table test data. Acceleration data from response analysis as the training data and shaking table test data as the verification data are utilized for machine learning, and damage state classification can be estimated.

[研究開発の目的及び経過]

地震直後の応急危険度判定は、現状では専門家による外観の目視等からの総合的な判定によっている。同判定の課題としては、災害後には応急危険度判定士が来られない、調査に時間がかかる等があげられる。

また、兵庫県南部地震や東北地方太平洋沖地震では、小破以下の建物でも、住民や建物管理者が判断できないという不安から、建物を継続使用できず住民等が避難所に避難する事例が多くみられ、地震後すぐに使える建物を簡易に判断する手法が求められている。

近年、人工知能（AI）の技術が注目されており、深層学習（Deep Learning）または機械学習（Machine Learning）を行うことにより、データから有用な規則、ルール、知識表現、判断基準などを抽出することが出来るため、自動的に判定が可能である。

本研究では、地震後に撮影した RC 柱等の建築部材の画像を対象にして、深層学習による学習を行い、応急危険度判定における評価基準の一つとなる建築部材の損傷度の予測可能性について検討する。また、鉄骨造フレームモデルの振動台実験の加速度データを利用し、機械学習による鉄骨梁端部の損傷状況の推定手法を適用する。

[研究開発の内容]

(1)画像の深層学習による建築物の損傷評価

建物管理者や住人がスマホ等で撮影した画像に基づき、深層学習により建物の部材等の損傷度等を判定するシステムについて検討を行う。

建築研究所の地震被害報告書等から、鉄骨造体育館（ブレースや露出柱脚基礎部等）や RC 造柱等の建物部材の写真を収集し、それらをデジタル化し、文献 1)の判定条件を簡素化した判定基準を適用し、鉄骨ブレースや

RC 造柱等の画像目視による損傷分類を行う。これらの画像に対して、深層学習の手法のひとつである畳み込みニューラルネットワーク²⁾（以下 CNN）を適用する。CNN は図 1 に示すように、画像を入力とする入力層から出力層へ向けて、畳み込み層とプーリング層を繰り返した後、何層かの全結合層をつなげた構造となっている。本検討では、CNN をゼロから学習させる代わりに、AlexNet³⁾や VGG-16³⁾等の転移学習を適用する。画像データのそれぞれの 70%を訓練用データとし、深層学習により、損傷度を判定する関数を構築する。残り 30%を検証用データとして、上記関数に適用し、正解率を求める。RC 柱の場合の画像の例を図 2 に示す。対象画像に対して、柱部分以外にはマスクをかけた。また訓練用データに関しては、元の画像データに変換（画像の反転・平行移動等）を加えることで、データ拡張を行う。

(2)加速度データの機械学習による建築物の損傷評価

建物内に設置した加速度センサの記録に基づき、機械学習により建物の損傷を検知するシステムについて検討を行う。

振動台実験等により、加速度データを得たら、特徴量を抽出する。特徴量は、ARX モデル⁴⁾等により得られた固有振動数、刺激関数等であり、特徴量は、複数の変数を合成して元の変数を減らし、全体を少数の変数で説明できるようにする主成分分析を行う。さらに、得られた主成分を入力データとして、機械学習を行い、鉄骨梁端部の損傷状況（梁端部損傷なし、梁端部亀裂あり、梁端部破断あり）の推定を行う。機械学習の適用においては、振動台実験データと応答解析データの両方を使用する。建物と損傷を模擬した解析モデルを作成し、この応答解析データを訓練データとして学習を行い、学習結果を振動台実験データに適用して検証を行う。対象試験体の解

析モデルの応答波形データにおいて、亀裂と破断の設定は、過去に実施されたスラブ付き梁試験体の加力実験から梁端の回転剛性の低下率を読み取ることで与えた。本手法は、E-ディフェンス振動台実験データや建築研究所が過去に行った振動台実験データ等に適用する。

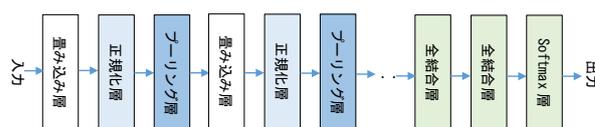


図1 畳み込みニューラルネットワークの例

【研究開発の結果】

(1)画像の深層学習による建築物の損傷評価

RC柱の画像を対象に、訓練用データを VGG16 の転移学習により学習し、検証用データに適用した推定結果の例を表1に示す。表1中の数字はRC柱の画像データ数である。表1の例では、正解率が78%であるが、訓練用データと検証用データに分ける方法はランダムなため、組み合わせにより正解率は73-83%の範囲であり、平均的には80%程度であった。他の建物部材でも同様な検討を行った結果、鉄骨造筋交いでは70%程度、鉄骨造柱脚部では81%程度、鉄骨造体育館天井筋交いでは85%程度の正解率であった。

(2)加速度データの機械学習による建築物の損傷評価

ここではE-ディフェンスの実大3層鉄骨フレームの振動台実験データ⁵⁾の結果について示す。試験体の立面図を図3に示す。機械学習において、各損傷ケース(梁端部損傷なし、梁端部亀裂あり、梁端部破断あり)それぞれ16データ、合計48データを学習データに使用した。振動台実験のデータを検証データとして用いるが、こちらも各損傷ケース(梁端部損傷なし、梁端部亀裂あり、梁端部破断あり)それぞれ16データ、合計48データとした。対象とした特徴量は、固有振動数と刺激関数とした。これらを用いた主成分分析を行い、機械学習として線形判別を適用した。推定結果を表2に示す。モデル建物の応答解析を訓練データとして、振動台実験データを検証データとして、線形判別により損傷状況を分類することが出来た。

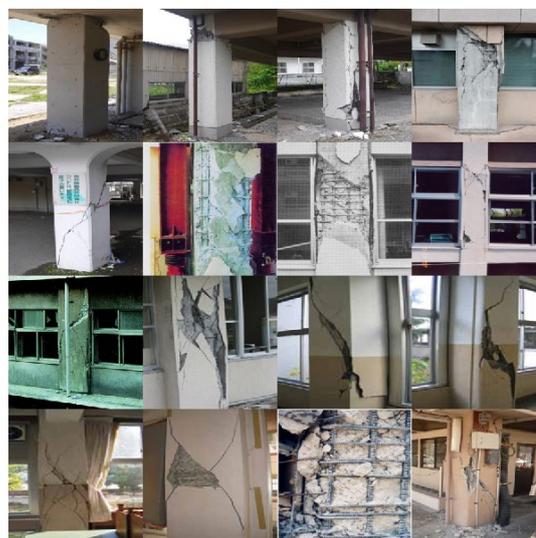


図2 RC柱の画像の例

表1 VGG16の転移学習による推定結果

	推定結果			
	損傷度 I, II	損傷度 III	損傷度 IV	損傷度 V
損傷度 I, II	17	6	0	0
損傷度 III	2	14	2	0
損傷度 IV	0	4	13	6
損傷度 V	0	0	1	31

【参考文献】

- 1) 日本建築防災協会：2015年改定版震災建築物の被災区分判定基準および復旧技術指針，2016.3
- 2) 岡谷貴之：深層学習，講談社，2015.4
- 3) <http://image-net.org/challenges/LSVRC/>
- 4) 足立修一：MATLABによる制御のためのシステム同定，東京電気大学出版局，1996
- 5) 国立研究開発法人防災科学技術研究所「E-Defense 実験データアーカイブ (ASEBI)」より課題名「地震によって損傷を受けた鉄骨建築物の耐震安全対策に関する実験研究」<https://doi.org/10.17598/nied.0020>

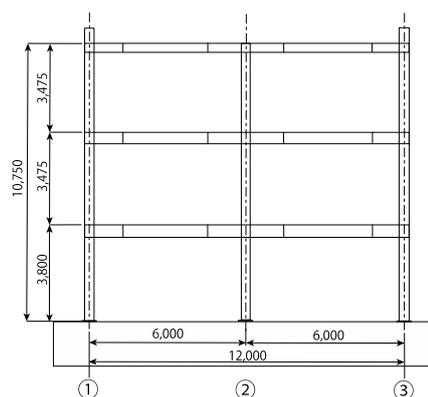


図3 対象試験体の立面図

表2 線形判別による推定結果

	推定結果		
	梁端部損傷なし	梁端部亀裂あり	梁端部破断あり
梁端部損傷なし	16	0	0
梁端部亀裂あり	0	16	0
梁端部破断あり	0	0	16