

熊本地震の罹災証明データを用いた深層学習による建物被害推定の可能性 Preliminary Study on Estimating Building Damage using Deep Learning based on Damage Assessment Data of Local Government after the 2016 Kumamoto Earthquake

○河辺 賢¹, 堀江 啓¹, 井ノ口 宗成², 松岡 昌志³, 須藤 巧哉⁴, 山崎 文雄⁴
Ken KAWABE¹, Kei HORIE¹, Munenari INOBUCHI²
Masashi MATSUOKA³, Takuya SUTO⁴, Fumio YAMAZAKI⁵

- ¹ MS&ADインターリスク総研株式会社 総合企画部
MS&AD InterRisk Research & Consulting, Inc.
- ² 富山大学大学院 都市デザイン学部
Faculty of Sustainable Design, University of Toyama
- ³ 東京工業大学 環境・社会理工学院
School of Environment and Society, Tokyo Institute of Technology
- ⁴ 千葉大学大学院 融合理工学府/工学研究院
Graduate School of Engineering, Chiba University

Insurance companies are required to estimate building damage rapidly and accurately when natural disasters occur. In this study, we analyzed the damage assessment data of local government and the estimated seismic motion of the 2016 Kumamoto Earthquake using deep learning method, and examined the possibility of estimating whether the building is totally collapsed or not. Multi-Layer Perceptron(MLP) was constructed using hyperparameters that was determined by K-fold cross-validation based on the analysis data. When test data that include 71% of a class that labeled “not totally collapse” was predicted by this trained MLP model, the classification accuracy was 80%, and the recall rate reached 90% in so far as only “not totally collapse” data was taken.

Keywords : Estimation of Building Damage, Kumamoto Earthquake, Deep Learning, Multi-Layer Perceptron

1.はじめに

損害保険会社では、自然災害発生時に迅速かつ正確な被害推定が求められる。被害推定手法には一般に過去の災害の知見をもとに構築された被害関数を用いられるが、新たに発生した災害に対する適用性に課題が指摘される。一方で、特微量の抽出が一見困難なデータから短時間でモデルを構築し未知のデータに対して高精度に予測する手法として注目されている深層学習は、今後リアルタイムに取得できるデータが整備されていくなかで、被害推定の迅速性と精度の向上に貢献する可能性がある。

本研究では、深層学習の手法の一つである多層パーセプトロン(Multi-Layer Perceptron, 以降 MLP と称す)を用いて、2016年熊本地震における建物被害情報と推定地震動情報を解析し、建物が全壊か否かについて判定を行い、深層学習手法の建物被害推定への活用可能性を検討した。

2.解析データ

以下に示す建物被害情報と推定地震動情報をGISソフトにより空間的に結合し、解析データを構築した。建物被害については、熊本県上益城郡益城町における罹災証明発行記録、被害認定調査結果および家屋課税台帳に基づくデータから、須藤ら¹⁾と同様の手法により10,159棟分を抽出した。パラメータには、被害クラス(2区分)、構造(5区分)、建築年代(4区分)、階数(5区分)、屋根形式(3区分)を採用した。なお被害クラスは被害認定調査における被災度区分のうち、大規模半壊、半壊、一部損壊、無被害を「全壊未満」とし、「全壊」との2つの被害クラスに区分した。各パラメータの内訳を図1に示す。また推定地震動については、松岡²⁾により250mメッシュで推定された本震の最大地表速度(PGV)と最大地表加速度(PGA)を使用し、これを建物被害情報と空間結合した(図2)。

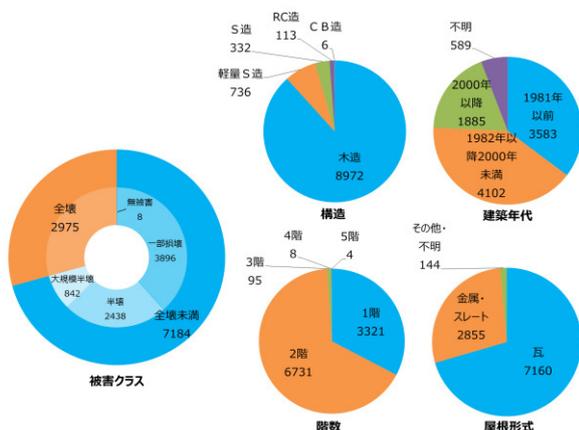


図 1 建物被害情報のパラメータ

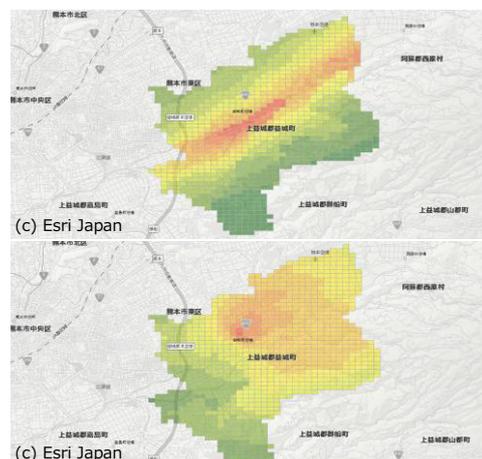


図 2 推定地震動情報 PGV(上)およびPGA(下)

3. MLPの構築

入力データを全壊未満もしくは全壊の2クラスに分類するMLPを構築した。各隠れ層のユニット数は同一、出力層はsoftmax関数を用いることを固定条件とし、その他の構造や最適化パラメータ(以降、ハイパーパラメータと称す)の組み合わせをMLPの性能が良くなるように探索した。まず、調整するハイパーパラメータの種類や値の候補を設定し、その組み合わせを20通りランダムに作成した。次に組み合わせそれぞれに対してMLPのK分割交差検証を実施し、正解率の平均値と標準偏差を20通り計算した。ここで、平均値が高く標準偏差が小さくなるようなハイパーパラメータの組み合わせを採用した。具体的なハイパーパラメータの候補と採用した値・手法を表1に、また採用値を用いて構築したMLPを図3に示す。なお、今回は解析データを10分割した交差検証を実施した。また、本研究ではPythonの深層学習のライブラリであるKerasを利用した。

表1 ハイパーパラメータの候補および採用した値や手法

ハイパーパラメータ		
種類	候補	採用
隠れ層の数	2, 3, 4	3
隠れ層のユニット数	64, 256	64
隠れ層の活性化関数	sigmoid, relu	relu
最適化手法	adam, rmsprop	adam
学習率	0.0005, 0.001, 0.005	0.001
バッチサイズ	32, 128	128
エポック数	20, 50, 100	50

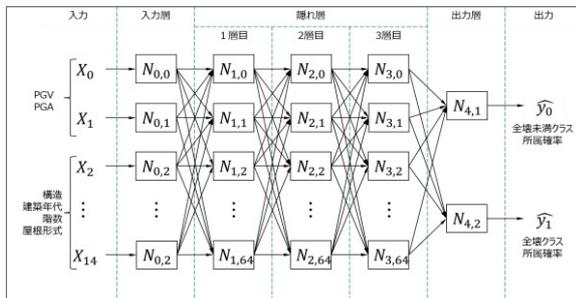


図3 構築したMLPの構造

4. MLPの学習と検証

解析データを概ね9:1の割合で学習データ9,143個と検証データ1,016個に分割した。なお、全壊未満および全壊のクラス比率を維持するよう層化分割法を用いた。この学習データを用いて前章で構築したMLPを学習させた結果を図4に示す。実線が学習データ、点線が検証データを入力データに用いた損失値および正解率だが、いずれもエポック数50程度で収束している様子が確認できた。

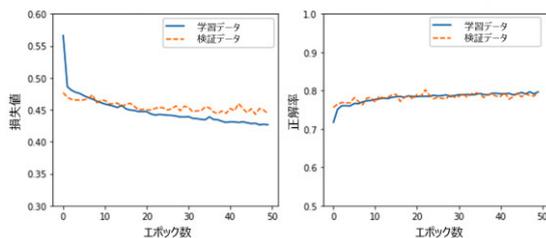


図4 学習過程 損失値(左)および正解率(右)

次に学習済みのMNNを用いて検証データの建物被害レベルを予測した。正解率は80%となり、解析データおよび検証データに含まれる全壊未満の割合71%よりも高く

なった。また、検証データに対する混合行列を表2に、再現率、適用率、F1値を表3に示す。全壊未満のクラスとした建物についての再現率は90%に達した。

表2 混合行列

	予測されたクラス		再現率	全壊未満 適合率	全壊 適合率
	全壊未満	全壊			
実際のクラス	645	73	90%	83%	69%
	135	163	F1値	86%	61%

表3 再現率・適用率・F1値

5. クラス所属確率の考察

構築したMLPは、入力データが各クラスに属する確率(以降、クラス所属確率と称す)を計算し、全壊のクラス所属確率が50%を超えた場合に全壊、それ以外の場合を全壊未満と予測する。図5に、被災度が大規模半壊以下の検証データ718個につき、予測された全壊のクラス所属確率をヒストグラムで示す。約9割は全壊未満と正しい予測をしており、一部損壊や半壊の検証データの予測精度が特に高い。また、図6に、被災度が全壊の検証データ298個につき、予測された全壊のクラス所属確率をヒストグラムで示す。過半数以上の163個については全壊と正しい予測をしたものの、確率が50%以下となり全壊未満と誤答した部分の精度向上は今後の課題である。

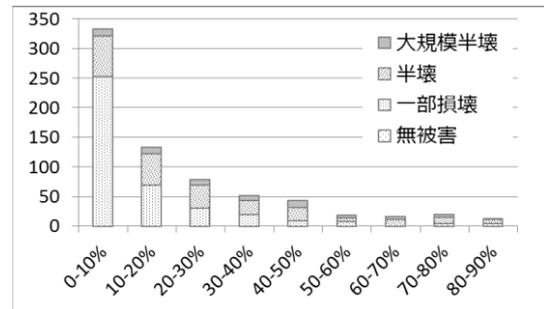


図5 被災度が大規模半壊以下の検証データの全壊クラス所属確率

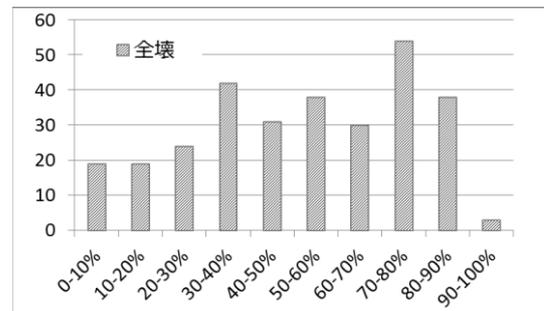


図6 被災度が全壊の検証データの全壊クラス所属確率

6. おわりに

熊本地震による建物被害情報と推定地震動情報を用いて、深層学習による建物全壊判定の可能性を検討した。学習済みのMLPで71%の全壊未満を含む検証データを判定したところ80%の正解率となり、特に被災度が大規模半壊以下の建物を全壊未満と推定する精度は90%に達した。自然災害発生時に取得した情報によりリアルタイムでMLPのような深層学習モデルを構築できれば、被害推定の迅速化や高精度化に貢献する可能性がある。

参考文献

- 1) 須藤巧哉ほか：罹災証明データに基づく2016年熊本地震における益城町の建物被害分析, 日本建築学会大会学術講演梗概集, 2018 (印刷中).
- 2) 松岡昌志：強震観測記録に基づく2016年熊本地震の地震動分布の推定, 地域安全学会梗概集, 2018 (印刷中).