

畳み込みニューラルネットワークによる建築物の被災度判定

Damage evaluation of building via convolutional neural network

肥田 剛典^{*1}
Takenori Hida

八百山 太郎^{*1}
Taro Yaoyama

高田 毅士^{*1}
Tsuyoshi Takada

^{*1} 東京大学大学院 工学系研究科 建築学専攻
Department of Architecture, Graduate School of Engineering, The University of Tokyo

In order to carry out prompt restoration activities after the occurrence of a natural disaster such as an earthquake, it is important to grasp the buildings' damage situation and damage distribution of the affected area as soon as possible. In this study, the buildings' damage is evaluated from the image data of building by using Convolutional Neural Network. Furthermore, to grasp the geographical distribution of the damage, a results of the damage evaluated by CNN are plotted on a map.

1. はじめに

2016 年熊本地震において、多くの建物被害が発生した。地震等の自然災害発生後に迅速な復旧活動を行うためには、可及的速やかに被災地の被害状況や分布を把握することが不可欠である。

本研究では、深層学習 (Deep Learning) の手法の一つである畳み込みニューラルネットワーク (Convolutional Neural Network [LeCun 98], 以降 CNN と記す) を用いて、建物の外観の画像データから被害の有無を判定する手法 [肥田 17] について検討する。さらに、CNN による被害判定結果を地図上に表示し、被害の地理的分布を把握する手法を構築する。

2. 画像データと CNN の概要

本研究で用いる建物画像の例を図 1 に示す。本研究では、木造、RC 造、S 造建物を対象とした。有被害建物の画像群は、2004 年新潟県中越地震、2007 年新潟県中越沖地震、2011 年東北地方太平洋沖地震、2013 年埼玉県越谷市竜巻被害および 2016 年熊本地震時に撮影した写真から構成される。従って、建物被害は地震の揺れによる被害の他、津波被害や竜巻被害を含む。無被害建物の画像は被災していない都市で無作為に撮影した健全な建物の外観の写真を用いることとした。無被害および有被害の写真をそれぞれ 1660 枚ずつ用いて、各画像を部分的に抽出し、または $\pm 5^\circ$ 回転させることにより、無被害画像と有被害画像をそれぞれ 24900 枚ずつ用意した。



図 1 学習に用いた建物写真の例




図 2 CNN の構造

連絡先: 肥田 剛典, 東京大学大学院工学系研究科建築学専攻, 東京都文京区本郷 7-3-1, hida@load.arch.t.u-tokyo.ac.jp

本研究で用いる CNN の構造を図 2 に示す。教師データとしては、無被害を 0、有被害を 1 として与えた。学習には用意した画像 49800 枚のうち 44820 枚の画像を用いることとし、残りの 4980 枚の画像を用いて学習結果の検証を行うこととした。

学習結果を図 3 に示す。損失率は学習開始から急激に下降する。正答率は学習開始から急激に上昇し、30 エポック付近で 92%程度に達する。その後、徐々に正答率が上昇し、500 エポック以降で 96%程度となった。

3. CNN による建物被害判定

2016 年熊本地震の被害調査を行い、その際に撮影した建物の外観の画像を用いて被害判定を行う。なお、ここで用いる画像は CNN の学習には用いていない。

CNN による被害判定結果と応急危険度判定結果を比較した例を表 1 に示す。写真 a および d では応急危険度判定結果と CNN による判定結果が対応している。これに対し、写真 b のように、外観に損傷が明瞭に表れない建物の被害判定は CNN では難しい可能性がある。また、写真 c のように樹木が多く撮影されている場合も誤判定となった。これらは今後の課題としたい。

熊本地震時の建物の被害写真に Grad-CAM [Selvaraju 17] を適用した例を図 4 に示す。この建物は、CNN により「被害有り」と判定された。CAM から、画像の左下部の影響が大きいことが分かる。この部位は、建物の崩壊により外壁が破壊され、断熱材や壁下地材が露出している部分に対応している。本稿で構築した CNN は、画像上のこのような特徴の有無から、建物の被害の有無を判定していると考えられる。

CNN による被害判定結果をさらに検証するため、建物被害の悉皆調査の結果 [国総研 16] と CNN による被害有無の判定結果を比較して図 5 に示す。CNN による被害判定では、写真を撮影した際の GPS 記録と被写体(建物)の位置が若干ずれることに注意が必要である。そのため悉皆調査結果と CNN による被害判定結果の位置が若干異なるものの、両者による被害判定結果の分布は概ね対応している。特に、県道 28 号線以南～秋津川の国道 443 号線以西の地域において悉皆調査で建物の大破倒壊率が 50%以上となっており、CNN による判定結果もほぼ全て「被害あり」と判定されている。このことから、CNN を用いた被害判定が概ね妥当であることが分かる。

4. 結論

本研究では、ディープラーニングの手法の一つである畳み込みニューラルネットワークを用いた地震時建物被害の判定手法について検討した。学習したモデルで予測された被害判定結果は 96%程度の正答率となり、概ね良好な精度で被害判定を行うことが出来た。2016 年熊本地震における建物被害を予測した被害分布は既往の悉皆調査の報告と概ね良好に対応した。これにより、本手法の妥当性が示された。

参考文献

[LeCun 98] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner: Gradient-based learning applied to document recognition. Proc. of the IEEE, Vol. 86, No. 11, pp. 2278-2324, 1998.

[肥田 17] 肥田剛典, 八百山太郎, 高田毅士:ディープラーニングによる地震時建物被害判定と被害の地理的分布推定手法, 日本建築学会大会学術講演梗概集(中国), 構造 II, pp. 417-418, 2017. 8

[Selvaraju 17] Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, and Dhruv Batra: Grad-CAM: Visual Explanations from Deep








図 3 学習結果

表 1 CNN による被害判定と応急危険度判定結果の比較

	a	b	c	d
建物画像				
応急危険度判定	調査済み	危険	調査済み	危険
CNN	被害無し	被害無し	被害あり	被害あり



a) 元の画像 b) 元画像+CAM

図 4 Grad-CAM による判定結果の可視化の例

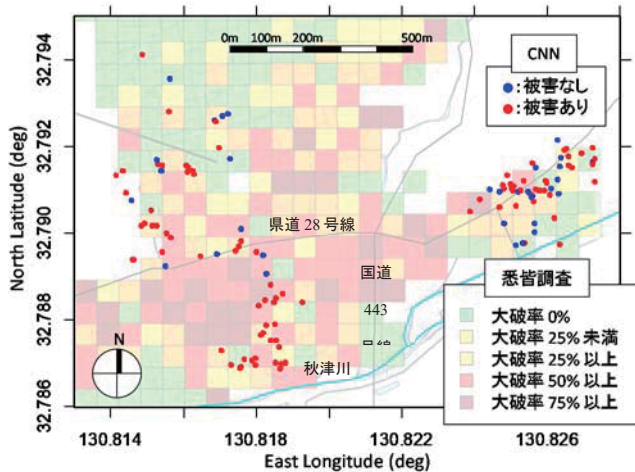


図 5 2016 年熊本地震における益城町の悉皆調査による建物の大破率⁵⁾と CNN による被害判定結果の比較

Networks via Gradient-based Localization, 2017 IEEE International Conference on Computer Vision, Venice, Italy, 2017. 10

[国総研 16] 国土総合技術研究所: 熊本地震における建築物被害の原因分析を行う委員会報告書, 2016. 9