

平成 30 年 6 月 19 日現在

機関番号：12608

研究種目：挑戦的萌芽研究

研究期間：2016～2017

課題番号：16K12834

研究課題名(和文)ディープ・ラーニングによる地震被害建物画像の機械学習と被災度の自動認識

研究課題名(英文) Damaged Building Recognition of the Earthquakes Using Deep Learning with Field and Aerial Photographs

研究代表者

松岡 昌志 (Matsuoka, Masashi)

東京工業大学・環境・社会理工学院・准教授

研究者番号：80242311

交付決定額(研究期間全体)：(直接経費) 2,700,000円

研究成果の概要(和文)：本研究は、建物被災度認定の効率化を目標に、コンピュータの機械学習により建物被災度を自動認識する手法開発を目的としている。1995年兵庫県南部地震および2016年熊本地震の被害建物を撮影した現地写真および航空写真に対して、建物被災度をタグ付けした膨大なサンプル画像データセットを作成し、ディープ・ラーニングのひとつであるCNNを用いて建物被害の特徴をコンピュータに学習させることで、建物被災度を自動認識するルールを作成し、その精度を検証した。その結果、外観被害のみに着目したデータセットを用いることにより判別精度は83.0%であった。また、震度情報を学習に加えることで、より詳細な被害程度に分類できた。

研究成果の概要(英文)：We conducted Convolutional Neural Network (CNN) for the 1995 Kobe earthquake and the 2016 Kumamoto earthquakes to learn images of damaged buildings, generated classifiers for building damage, estimated the building damage and compared with the field survey data. As a result from the Kobe dataset, it became clear that buildings with severe damage can be identified with accuracy of 86.0% for aerial photographs and 83.0% for field photographs. In addition, from the photograph of the site it became clear that the collapsed building can be identified with an accuracy of 98.5%. Also, for the purpose of supplementing the point that not all damage parts can be judged from aerial photographs, estimated seismic intensity at the location of the building was added to the input of learning of CNN. As a result from the Kumamoto dataset, it was shown that there is a possibility of detailed estimation of building damage degree based on the severely damage probability output from CNN.

研究分野：地震工学

キーワード：地震建物被害 被災度判定 深層学習 航空写真 現地写真

### 1. 研究開始当初の背景

地震が発生した際に、被災地の建築物の被害程度を調査することは、災害対応、復旧・復興計画を策定する上で重要であり、建設技術者や自治体の職員が現地に赴き、外観や内部の目視により損傷箇所を特定し、損傷が占める割合によって被災度を判定する。しかし、このような詳細な調査は人手と時間がかかることから、発災直後は甚大被害地域の特定や被害の全体造の把握に被災地を撮影した航空写真や人工衛星画像の目視判読や画像処理によって被害建物を把握することが多いが、導き出す被害把握手法の精度は被害認定調査等の実務に使えるほど高くはない。一方、既往調査や研究にてこれまで蓄積した被害建物を撮影した画像は膨大な数になっている。これらの膨大なデータセットを有効活用すると共に、近年、計算機能力の向上と高度なアルゴリズム開発によって爆発的な発展をしているディープ・ラーニングによる機械学習を適用することで、コンピュータによる迅速かつ新たな被災度認識の枠組みが提案できる。

### 2. 研究の目的

地震後の建物被災度認定は、被災者の生活再建や都市の復興に影響を与える。従来、自治体等の職員が認定作業を行うが、広域災害の場合には対象建物数の増大と人手不足により、被災度認定に多大な時間を要してきた。本研究は、建物被災度認定の効率化を目標に、コンピュータの機械学習により建物被災度を自動認識する手法開発を目的としている。具体的には、既往地震の被害調査データを収集し、被害建物を撮影した現地写真および航空写真に対して、建物被災度をタグ付けした膨大なサンプル画像データセットを作成する。サンプル画像データを入力に、ディープ・ラーニングを用いて建物被害の特徴をコンピュータに学習させることで、建物被災度を自動認識するルールを作成し、その精度を検証する。

### 3. 研究の方法

コンピュータに地震による建物被害を機械学習させるためには、入力用に膨大なデータセットが必要になる。そこで、1995年兵庫県南部地震の地震被害調査データを収集し、現地写真および航空写真と建物被災度をタグ付けしたサンプル画像データを作成する。また、2016年に発生した熊本地震についても航空写真を入手し、目視による被害判読を行うことでサンプル画像データを作成する。機械学習アルゴリズムはディープ・ラーニングを用いる。その中でも物体カテゴリ認識に有効なCNN(Convolutional Neural Network: 畳み込みニューラルネットワーク)を用いて、被害建物の画像に共通する特徴を反復計算により学習させる。そして、機械学習で認識できる被害と実務で実施されているり災

調査の建物被害認定データ等での被災区分の比較を行い、コンピュータによる被害判別の精度を明らかにする。

### 4. 研究成果

#### (1) 兵庫県南部地震の現地写真を用いた深層学習による建物被災度判別

兵庫県南部地震で被害を受けた西宮市全域を対象地域とした。被災度データは震災復興都市づくり特別委員会の建物被災度判別結果について、建築研究所がデジタル化したGISデータに、西宮市り災調査データおよび現地写真を統合した西宮 Built Environment DB(以後、西宮 DB と呼ぶ)を用いた。り災調査データは「全壊」、「半壊」、「一部損壊」、「無被害」の4段階に分けられているが、本研究では初歩的な検討として、「半壊」から「無被害」を「その他」として統合し、「全壊」と「その他」の2区分を被災度情報として用いた。

次に、西宮 DB の建物ポリゴンと写真撮影ポイントから建物を機械的に特定し、建物が画像のほぼ中心にくるように現地写真を切り出し、さらに、256×256ピクセルにリサイズした画像を建物ごとに作成した。「全壊」と「その他」の建物数は同じにしている。

図1に本研究の学習に用いたCNNの層構成を示す。全結合層とは通常のニューラルネットワークの層を指す。また、本研究では学習のミニバッチサイズは100とし、学習の反復は15,000回、学習率は0.001、減衰負荷係数は0.0005、モメンタムは0.9として学習を行った。CNNでは学習と検証の段階が交互に行われる。それぞれの段階に用いるデータを学習データと検証データと呼び、異なるデータを用いるのが一般的である。学習段階では判別器の出力と正解との誤差が小さくなるようにパラメータ等の更新を行って精度向上をはかる。一方、検証段階では判別器の出力と正解との誤差を評価し、学習が正常に行われているのかの検証を行う。正常に学習が行われないと、学習誤差と検証誤差が大きく乖離する過学習と呼ばれる状態になる。過学習が発生すると学習データのみは正しく判別できるが、それ以外のデータは正しく判別できなくなり、判別器の汎用性がなくなる。過学習を避けるには、学習データの画像の枚数を水増しするデータ拡張と呼ばれる方法などが知られている。




図1 学習に用いたCNNの層構成

本研究では、8:2の割合で学習データ、検

証データを分けた。さらに、過学習対策として、切り出し範囲を移動させることでデータ数を 20 倍に拡張させたデータセットも作成した(表 1 参照)。

表 1 学習に用いた画像数

	「全壊」		「その他」	
	学習	検証	学習	検証
切り出し直後	1,249		1,249	
データ拡張なし	999	250	999	250
データ拡張あり	19,980	250	19,980	250

データ拡張なしのデータセットに CNN を適用したところ、学習の反復が 6,000 回を超えたあたりから検証誤差が大幅に増加し、過学習が発生することを確認した。一方、データ拡張したデータセットは過学習を抑制できた。判別器の混同行列を表 2 に示す。判別精度はデータ拡張なしが 54.8%, データ拡張ありが 73.6%であり、後者は判別精度が 19 ポイント程度向上している。図 2 にデータ拡張ありの判別器の判別例を示す。TP の上段の画像など、完全に倒壊している建物の画像では、確信度が 1 に近づいて『全壊』と判断する例が多かった。TN の下段の画像など、建物の形状が残っている画像では、確信度が 0 に近づいて『その他』と判断する例が多かった。しかし FN の画像では、「全壊」ではあるが被害が確認できない建物や明らかに倒壊した建物が確認でき、FP では比較的健全な建物が『全壊』と判別される誤判別がみられる。り災調査による被災度は、建物によっては外観だけから判定していないことや「その他」の画像であっても被害を受けた建物が写り込んでいる場合や大規模な生け垣やベランダ等の存在がこれらの誤判別の原因と考えられる。

そこで、「全壊」で被害が確認できる画像と「その他」で「全壊」の建物が写り込んでいない画像を目視で選定してデータセットを再構築して学習させたところ、その判別器の判別精度は 83.0%に向上した。目視にて倒壊が確認できる建物 66 棟については 65 棟を大被害と確認できる建物 81 棟については 62 棟を正しく『全壊』と判定した。

表 2 検証データに対する判別器の混同行列

		判別結果			
		データ拡張なし		データ拡張あり	
		『全壊』	『その他』	『全壊』	『その他』
正解	「全壊」	126 (TP)	124 (FN)	205 (TP)	45 (FN)
	「その他」	102 (FP)	148 (TN)	87 (FP)	163 (TN)

以上より、西宮 DB に含まれる兵庫県南部地震のり災調査データと現地写真のデータセットを作成し、CNN を適用することで、建物被災度判別の可能性を検討した。その結果、過学習を抑制したデータセットを用いることで、73.6%の精度で全壊とそれ以外の被災度に判別できた。また、外観被害のみに着目したデータセットを用いることにより判別

精度は 83.0%に向上することがわかった。しかし、現状で高い精度にて判別可能な被害は倒壊など全壊の建物の一部に限られ、「半壊」や「一部損壊」のような建物被害の判別は今後の課題である。



図 2 検証データに対する判別器の判別例 (数字は確信度)

(2)2016 年熊本地震の空中写真を用いた深層学習による建物被害分類

熊本地震にて多くの建物に被害が確認されている熊本県益城町役場周辺を対象地域とした。学習には 4 月 14 日に発生した地震(以下、前震)の後と、15 日の地震(以下、本震)の後にそれぞれ撮影された 2 種類の空中写真(ADS 画像・PALS 画像)と目視判読データ(以下、目視 DB)を用いた。学習後、建築学会による現地調査データ(以下、学会 DB)を用いて評価を行った。

ADS 画像は航空機からラインセンサと呼ばれる航空カメラから連続的に直下視撮影された画像で、オルソ化してある。PALS 画像は航空機から斜めに撮影された画像である。各画像は、建物が収まる大きさに切り出した後、256×256 ピクセルにリサイズをしている。

目視 DB とは建物破壊パターンチャート内の Damage Grade を参考に ADS 画像と PALS 画像から目視により被害を判読したデータである。本研究の目視 DB で扱う Damage Grade は、「被害が確認できない建物」を「Dk0」,「壁面に亀裂・漆喰壁の小片落下」や「屋根瓦の一部が破損」を「Dk1」,「多くの壁に亀裂・漆喰壁の落下が目立つ」や「屋根瓦全体の 1/3 程度が破損」を「Dk2」,「ほとんどの壁に大きな亀裂・構造要素の一部が破損」や「屋根瓦全体の 2/3 程度が破損」を「Dk3」,「壁面は重度の破壊・構造要素が連結性を失っている」や「屋根瓦のほぼ全てが破損及び一部が崩壊」を「Dk4」,「完全またはほとんど完全に崩壊」を「Dk5」とした。図 3 に各被害程度の例を示す。なお、前震後と本震後のそれ

それぞれについて目視 DB を作成した。




図3 目視判読データの画像例

学会 DB は、Damage Grade を参考に日本建築学会により行われた外観調査をまとめた被害程度であり、「D0」から「D6」の7段階で表される。「D6」は、「D5」の内、建物が「崩壊」しているものを表す。図4に本震後の目視 DB の被害程度に対する学会 DB の被害程度が占める割合を示す。「Dk5」の約75%は学会 DB における「D6」であり、「D5」も含めると約90%を占める。また「Dk0」は、50%以上が「D0」であり、「D1」を含めると約90%を占める。学会 DB は現地にて被害箇所を確認しているが、目視 DB は建物内部の被害や被害箇所が写っていないものがあるため被害を過小に評価したと思われる。これらより、本研究の CNN で学習に用いる目視 DB の被害程度は、他の被害程度に比べて信頼性が高い「Dk0」と「Dk5」を用いることとする。なお、各建物画像には1棟ごとに目視 DB と学会 DB の被害程度を紐付けした。

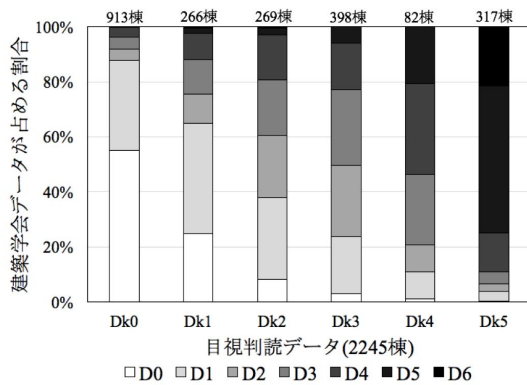


図4 目視判読データと建築学会データの関係

本研究で用いた CNN の層構成を図5に示す。層構成とは別に学習に使用するハイパーパラメータは、ミニバッチサイズを100枚、学習の反復回数を15,000回、学習率を0.001、減衰係数を0.0005、モメンタムを0.9とした。




図5 CNNの層構成

ADS 画像（直下視）と壁面情報を含む PALS 画像をそれぞれ学習させ、PALS 画像が被害推定に有効かを確認する。表3に使用する ADS 画像と PALS 画像の枚数を示す。「学習データ」とは、学習時に CNN に入力する画像である。今回は、過学習（学習により作成される学習モデルが学習画像に過剰に適合してしまい汎化性能が低下すること）を抑制する目的で24倍（90度ごとに回転と鏡像反転、コントラストの増加と低下）の水増しをおこなった（水増した画像数は表内の「」以降に表示）。「検証データ」とは、学習が繰り返される度に作成される学習モデルに入力する画像で、推定された被害程度と実際の被害程度とを比較し、この違いが少なくなるようニューラルネットワークの重みを決定するのに用いられる。これらとは別に、対象地域内のすべての建物画像から構成される「評価データ」を作成した。このデータを用いて、学習に用いた被害程度（「Dk0」と「Dk5」）の判別精度の検証を行うと共に、学会 DB の建物被害データの判別の可否を明らかにする。ADS 画像と PALS 画像のどちらについても「評価データ」は本震後の画像を用いるが、「学習データ」と「検証データ」は、ADS 画像の学習は本震後の画像を用いるが、PALS 画像は本震後の撮影範囲が狭く、画像数が少ないため前震後の画像を用いた。

表3 ADS 画像と PALS 画像の枚数

		目視判読データ						total
		Dk0	Dk1	Dk2	Dk3	Dk4	Dk5	
ADS 画像	学習データ	261 →6264	0	0	0	0	261 →6264	522 →12528
	検証データ	262	0	0	0	0	262	524
	評価データ	1479	424	433	554	125	527	3542
PALS 画像	学習データ	66 →1584	0	0	0	0	66 →1584	132 →3168
	検証データ	61	0	0	0	0	61	122
	評価データ	2855 実棟数 638	921 実棟数 209	823 実棟数 175	1139 実棟数 251	317 実棟数 70	2269 実棟数 368	8324 実棟数

図6に ADS 画像と PALS 画像の学習による判別精度と誤差の推移を示す。ADS 画像は、学習の反復が9,000回前後で判別精度がピークに達し、以降は87%程度である。PALS 画像は、学習の反復回数が2,000回程度で85%程度となり、以降は80%程度である。この違いは、PALS 画像は学習に用いている画像の枚数が少なく、被害の特徴も少ないためであると考えられる。誤差は判別精度の上昇とともに低下した後、判別精度が安定する頃には、検証誤差が上昇を始めている。この現象は過学習と呼ばれる。そこで、ADS 画像の学習では過学習が始まる前の8,600回、PALS 画像の学習では2,200回の状態（学習済みモデル）を用いて評価用データの評価を行い、目視判読データおよび現地調査データの判別結果と比較した。

学習済みモデルに評価用データの画像を入力すると、その画像が何パーセントの確率で「Dk5」であるかを表す指標（以下、確信

度)が出力される。この確信度が50%以上を「Dk5」、50%未満を「Dk0」として判別結果をまとめた。PALS画像は、ひとつの建物を様々な方向から撮影しているため、同じ建物でも画像ごとに異なる確信度が出力される。本研究では、それらの平均値を用いることとする。学習時の判別精度(図6参照)では、ADS画像とPALS画像はどちらも80%以上の高い値が得られているが、学会DBを評価対象にした場合にはPALS画像はADS画像に比べて判別精度が低かった。その原因として本研究で用いたデータセットの枚数がPALS画像は極端に少なかったことが原因として考えられる。




図6 ADS画像とPALS画像の学習の推移、(a)判別精度の推移、(b)誤差の推移

各建物の立地場所における計測震度の推定値から震度画像を作成し、ADS画像とともに学習時に入力することで目視DBからの学会DBの被害程度の推定を試みる。震度画像の値は、計測震度を以下の式により0から255に変換している。

$$DN=255(INT-5.0)/(7.5-5.0) \quad (1)$$

ここでDNは震度画像の値、INTは建物立地場所における前震と本震の計測震度のうち大きい値、7.5と5.0は建物被害が想定される計測震度の範囲の上限と下限である。

図7に震度画像ありとなしの学習の推移を示す。震度画像を用いることにより、短い反復回数で判別精度がピークに達する。これは、1回の学習でCNNに与えられる情報が増えたためであると思われる。

確信度に50%の閾値を設定して行う判別では、震度画像の有無にかかわらずADS画像による「D0」と「D5」と「D6」の判別精度は90%程度であることがわかる。また、表4内の「D1」から「D4」において、「Dk5」と判別された被害棟数数の割合に注目すると、学会DBの被害程度が大きくなるにつれて「Dk5」に判別される建物数が多くなることわかる。




図7 ADS画像における計測震度ありとなしの学習の推移、(a)判別精度の推移、(b)誤差の推移

目視判読の「Dk0」と「Dk5」の画像のみを学習して、被害程度を詳細に分類することを目的に、「Dk5」への確信度と被害程度の間を調査した。ADS画像の学習済みモデルによる評価データの確信度と学会DBの被害程度の間を調査した。ADS画像と震度画像の学習済みモデルによる評価データの確信度と学会DBの被害程度の間を調査した。ADS画像のみを用いた学習済みモデルによる分類において「D2」から「D4」の間に違いがほとんどみられないが、震度画像を加えた学習済みモデルでは、被害程度に応じて中央値にやや違いがみられる。




図8 ADS画像による建築学会データの分類結果




図9 ADS画像+震度画像による建築学会データの分類結果

そこで、ノンパラメトリックな有意差検定手法の1つであるMann-Whitney U testにより、それぞれの確信度の傾向が、隣り合う被害程度との間に有意な差があるかを検定した。その結果、ADS画像のみでは、「D2」から「D4」のそれぞれの被害程度の間には有意な差はみられなかったが、震度画像を追加することにより「D2」から「D4」の間に有意な差が生まれた。このことから、震度画像を加えることで、被害程度の細分化が行える可能性があることが明らかになった。

## 5. 主な発表論文等

(研究代表者、研究分担者及び連携研究者には下線)

〔雑誌論文〕(計1件)

石井友, 松岡昌志, 牧紀男, 堀江啓, 田中聡: 兵庫県南部地震後に撮影された航空写真と現地写真を用いた深層学習による

る建物被災度判別の試み，日本建築学会  
論文集，No.751，2018.9.（印刷中）

〔学会発表〕（計7件）

石井友，松岡昌志，中村良介，彦坂修平，  
今泉友之，藤田藍斗，伊東里保：東日本  
大震災における被災後の高分解能衛星画  
像を用いた深層学習による建物流出認識，  
日本リモートセンシング学会第61回学  
術講演会論文集，pp.129-130，2016.11.

釜ヶ谷悠馬，松岡昌志，小岩弘道，望月  
貫一郎：空撮画像の目視判読による熊本  
地震前震および本震の益城町とその周辺  
の建物被害，地域安全学会梗概集，No.39，  
pp.91-92，2016.11.

石井友，松岡昌志，牧紀男，堀江啓，田  
中聡，中村良介，彦坂修平，今泉友之，  
藤田藍斗，伊東里保：兵庫県南部地震の  
現地写真および空撮写真を用いた深層学  
習による建物被災度判別，地域安全学会  
梗概集，No.39，pp.86-88，2016.11.

釜ヶ谷悠馬，松岡昌志，小岩弘道，望月  
貫一郎：熊本地震の空中写真を用いた深  
層学習による建物被害推定の検討，日本  
地震工学会・大会-2017梗概集，CD-ROM，  
P4-30，10p.，2017.11.

釜ヶ谷悠馬，松岡昌志，小岩弘道，望月  
貫一郎：2016年熊本地震による建物被害  
を対象とした深層学習による被災度分類  
の試み，地域安全学会梗概集，No.41，  
pp.185-186，2017.11.

上岡洋平，田中聡，阿部郁男，釜ヶ谷悠  
馬，松岡昌志：2016年熊本地震における  
斜め航空写真を用いた目視判読および深  
層学習による建物被害判別の検討，地域  
安全学会梗概集，No.41，pp.127-30，  
2017.11.

石井友，松岡昌志，牧紀男，堀江啓，田  
中聡：兵庫県南部地震の現地写真を用い  
た深層学習による建物被災度判別，日本  
建築学会大会学術講演梗概集，構造，  
pp.415-416，2017.8.

〔図書〕（計0件）

〔産業財産権〕

出願状況（計0件）

取得状況（計0件）

〔その他〕

ホームページ等

画像処理による被害把握の実践と成果

<https://sites.google.com/site/matsuokamtokyotech/research/response>

6. 研究組織

(1) 研究代表者

松岡 昌志 (MATSUOKA, Masashi)  
東京工業大学・環境・社会理工学院・准教  
授  
研究者番号：80242311

(2) 研究分担者

なし

(3) 連携研究者

なし

(4) 研究協力者

牧 紀男 (MAKI, Norio)  
京都大学・防災研究所・教授

田中 聡 (TANAKA, Satoshi)  
常葉大学・大学院環境防災研究科・教授

中村 良介 (NAKAMURA, Ryosuke)  
産業技術総合研究所・人工知能研究センタ  
ー・チーム長