

## 車載カメラ画像の深層学習による道路の地震被害の自動抽出

Extraction of Road Damage after an Earthquake Using Deep Learning Model

17WM1341 瀬崎 陸  
Riku Sezaki

指導教員 丸山 喜久

## SYNOPSIS

The Kumamoto earthquake, which occurred on April 16, 2016 with the moment magnitude of 7.0, caused severe damage to the road network in Kumamoto Prefecture. This study tries to detect the earthquake-induced damage to the roadways using the images captured by a vehicle-mounted camera. To achieve the objective, the authors try to develop an image classifier to detect the earthquake-induced damage to the roadways based on deep learning algorithm. A deep learning module CAFFE was employed in this study to develop an image classifier. Then, the authors verified the accuracy of the image classifier. In this study, the overall accuracy was 81%. The results were visualized using grid cells with the size of 50 × 50 m to compare with the actual damage situations.

## 1. はじめに

2016年4月に発生した熊本地震では、震源に近い熊本市、西原村、益城町を中心に甚大な被害をもたらした。とくに4月16日に発生したマグニチュード7.3の本震の影響で被害はより大きいものとなり、多数の人的被害、建物被害に加え、道路被害が多発したり。

道路ネットワークは負傷者の搬送、救援物資及び重機の搬入に非常に重要であり、発災後できるだけ早く道路状態を把握する必要がある。現状、道路被害を認識する手段は自治体職員による目視での確認が一般的<sup>2)</sup>であり、時間を要し、職員の業務負荷も大きい。

近年、画像認識の新たな方法として、ディープラーニングが注目されている<sup>3)</sup>。従来のBag-of-keypointsなどのピクセルベースの手法は、画像の判別に画像特徴量や画像特徴点を設定する必要があるが、これらの設定値が判別精度に大きな影響を与える<sup>4)</sup>。これらの既往研究には、例えば道路のひび割れをテンプレートマッチングにより検出する服部ら<sup>5)</sup>の手法や、特徴点の順序付けにより顔検出を行う堀田ら<sup>6)</sup>の研究などがある。これに対しディープラーニングは特徴量や特徴点まで学習するため、人がこれらを設定する必要がなく、画像認識の分野で従来よりも大幅に高い精度を示すようになってきている<sup>7)</sup>。

そこで本研究では、2016年4月17日、20日に熊本地震の被災地周辺で撮影した車載カメラ画像を用いて、ディープラーニングに基づく判別モデルの作成を行い、精度の検証を行った。また、判別モデルを用いた早期被害把握を想定したシミュレーションとして、4月22日、25日、26日に撮影された画像を判別させ、精度の検証及び考察を行った。

## 2. 対象地域と使用データ

熊本地震発生後の2016年4月17日と4月20日に、熊本県益

城町周辺でグローバル・サーベイ株式会社によって撮影された連続写真を深層学習に使用した。まず、連続写真を目視判読し、道路閉塞(建物の倒壊などによって、道路の一部が障害物で覆われ、車の通行に影響を与える場合)、道路被害(地震によるひび割れ、段差など)、無被害の3種類に分類した。さらに、それらを道路路面のみを学習させるために画像下部をトリミングし、512×75ピクセルに解像度を変更し、深層学習に使用した(図1)。なお、前処理としてこれらの画像を正規化した。自然画像を入力とする本研究では、入力画像の全体的な明るさやコントラストの違いを吸収する必要がある。例えば、画像が撮影される時のカメラの露出(シャッタースピードなど)や太陽光の当たり方で画像全体の明るさやコントラストは大きく変化する。この問題を解決するため、あらかじめ全画像を正規化した<sup>8)</sup>。

画像を3種類に分類する際には、まず6人が31,951枚の画像を目視で道路閉塞、道路被害、無被害に分類した。6人中5人以上が道路閉塞、道路被害と分類した画像を道路閉塞、道路被害としてディープラーニングに使用することとした。また、無被害に関しては6人全員がそのように目視で分類した画像を用いた。この結果、道路閉塞と分類された画像は512枚、道路被害は673枚、無被害は14,346枚となった。この中から、ランダムに道路閉塞412枚、道路被害573枚、無被害7132枚を教師用画像として抽出した。深層学習に用いる道路閉塞、道路被害の画像の枚数を増やすため、これらの画像はコントラストを3段階変化させ、さらに左右反転させ、もとの画像の6倍の枚数にした<sup>9)</sup>。つまり、道路閉塞2472枚、道路被害3438枚、無被害7132枚を教師用画像とした。

教師用画像として使用しなかった各分類100枚ずつ計300枚を判別精度の評価画像として判別モデルの精度の検証に



図1 使用した画像例

用いることとした。さらに、画像判別モデルを用いた早期被害把握を想定したシミュレーションには、2016年4月22日、25日、26日に西原村、益城町、御船町、甲佐町で撮影された画像、5999枚を使用した。これらの画像も判別モデルを作成する際と同様に、512×75ピクセルに解像度を変更し、正規化した後に使用した。

### 3. 深層学習

教師用画像を深層学習させることにより判別モデルの作成を行う。本研究では、深層学習のフレームワークとしてCAFEE(convolutional architecture for fast feature embedding)を用いた。ネットワークの構成にはリファレンスモデルであるcifar10のモデルを一部改変したものをを使用した。ここでは、入力層が1層、畳み込み層は5層、プーリング層が5層、全結合層が2層、出力層が1層とした。

畳み込み層<sup>10)</sup>(図2)は、画像の局所領域において式(1)に示す畳み込み処理を行い、入力データに対しフィルタをかけることで情報の圧縮を行う。ここで $\phi$ は活性化関数、 $w$ はフィルタ、 $K$ は $N-1$ 層目の特徴マップ、 $b$ はバイアスである。

$$h_j^n = \phi\left(\sum_{k=1}^K h_k * w_k^n\right) + b_k \quad (1)$$

プーリング層<sup>11)</sup>(図3)は式(2)で表され、一般に畳み込み層の直後に設置される。畳み込み層で得られたフィルタ応答の位置感度を低下させることで、微小な平行移動に対する不変性を実現するはたらきを持つ層である。これらのネットワークを多段に重ねることにより、中間ノードに画像を構成する基底のイメージが抽出される。

$$h_j^n(x, y) = \max h_j^{n-1}(\bar{x}, \bar{y}) \quad (2)$$

全結合層<sup>12)</sup>とは、畳み込み層とプーリング層の繰り返し後に隣接層のユニットが全結合した層である。一般に複数連続して配置される。最後の出力層は、順伝搬型ネットワークと同様に、目的がクラス分類の本研究では、式(3)

のソフトマックス関数となる。ここで、 $y_k = z_k^{(L)}$ は出力、 $k$ が判別したいユニットである。出力層 $l=L$ の各ユニット $k(=1, \dots, k)$ の総入力は、一つ下の層 $l=L-1$ の出力をもとに、 $u_k^{(L)} = W^{(L)}z^{(L-1)} + b^{(L)}$ と与えられる。

$$y_k \equiv z_k^{(L)} = \frac{\exp(u_k^{(L)})}{\sum_{j=1}^K \exp(u_j^{(L)})} \quad (3)$$

教師用画像を図4のニューラルネットワークを使用し、60000回学習させ画像判別モデルの作成した。判別モデルの検証には精度評価用画像計300枚をすべて判別させ、その判別精度を検証した。

その結果、学習8000回時の判別モデルが81.0%と最も精度が高かったため本研究での判別モデルとした(表1)。無被害は非常に高精度で判別可能であるが、道路被害は正しく判別する精度が66.0%とやや低かった。

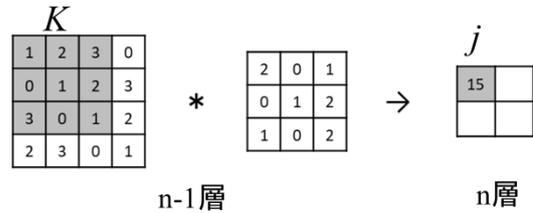


図2 フィルタによる畳み込み層

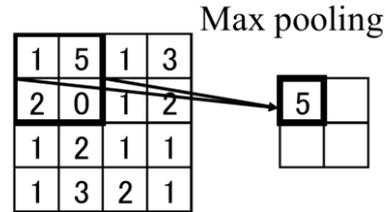


図3 プーリング層

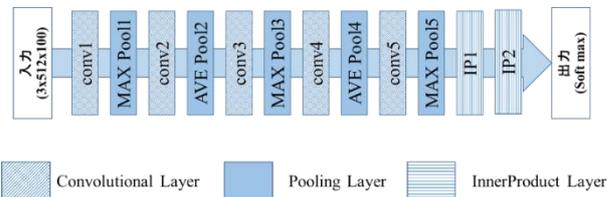


図4 使用したニューラルネットワーク

表1 検証用画像の精度

		予測結果			検出精度	全体精度
		道路閉塞	道路被害	無被害		
正しい分類	道路閉塞	87	9	4	87.0%	81.0%
	道路被害	15	66	19	66.0%	
	無被害	6	4	90	90.0%	

### 4. 地震被害の早期把握に向けたシミュレーション

作成した判別モデルを使用し、実際の使用を想定したシミュレーション手法を行った。使用した画像は2016年4月22日に熊本県西原村で5m間隔に撮影された画像1483枚である。あらかじめ被害の有無を1人が目視判別し、判別モデルに判別させ、精度を検証した。全体精度は78.8%となった。道路閉塞の検出精度は56.3%、道路被害の検出精度は34.6%、無被害の検出精度は91.6%であり、とくに道路被害の判別精度が低かった。

目視判別した結果と判別モデルが算出した結果を地図表示したところ大まかな被害発生箇所は認識可能であるが、無被害と道路閉塞が混在しているエリアなど実際に被害が発生しているか不明瞭なエリアが多く、実用化を想定した際、道路管理者が素早くどこに被害が発生しているか把握することが困難であることが予測された。

そこで地図上を50mメッシュで区切り、メッシュ内の全画像数に対する道路閉塞と道路被害の和が占める割合によってそのメッシュ全体を道路変状メッシュと無被害メッシュに2分類した。目視による被害状況の地図に関しては、メッシュ内に道路閉塞と道路被害のいずれかが1点以上存在すればそのメッシュを道路変状メッシュとし、全ての点が

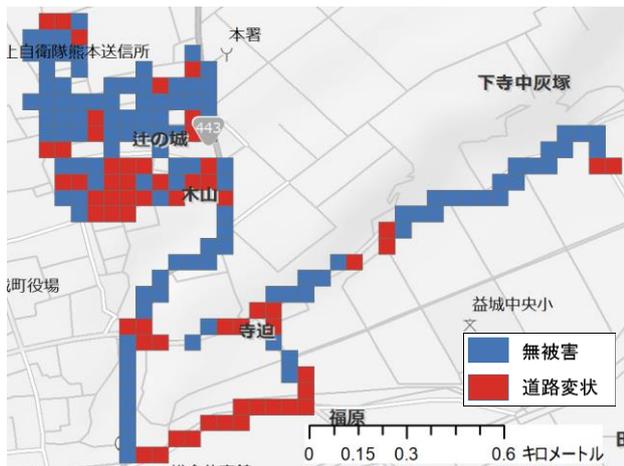


図5 ケース1の目視判読のメッシュ表示

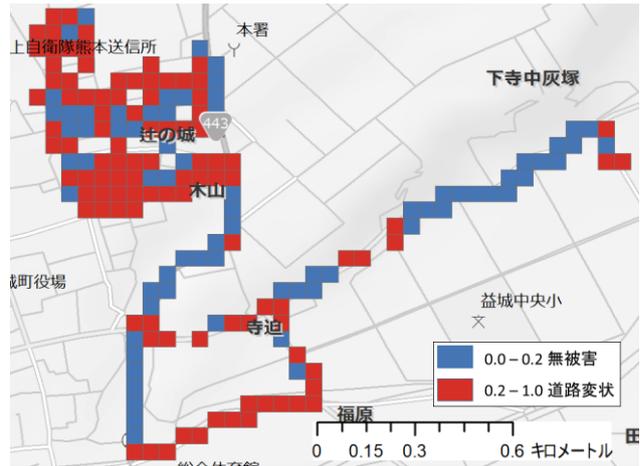


図6 ケース1の判別モデルの結果のメッシュ表示

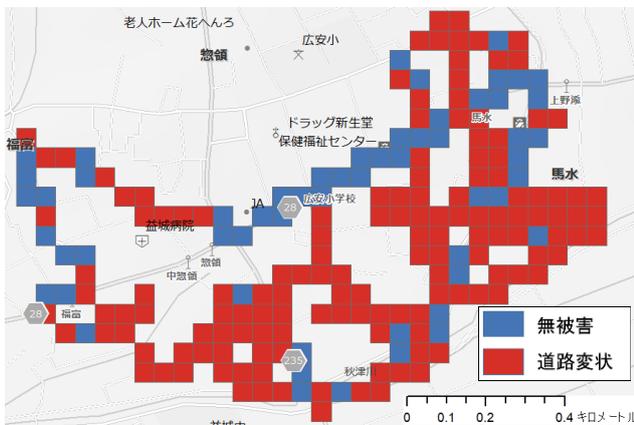


図7 ケース2の目視判読のメッシュ表示

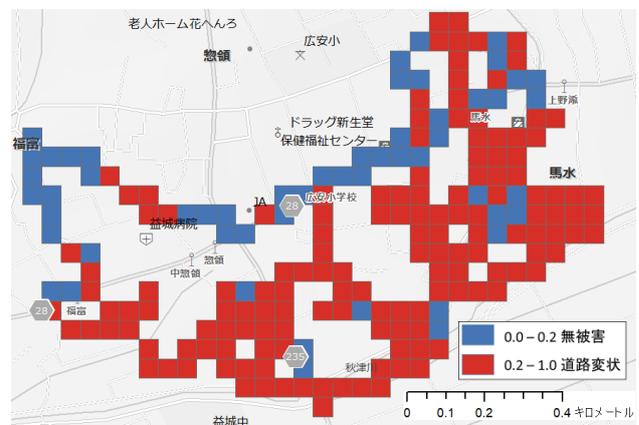


図8 ケース2の判別モデルの結果のメッシュ表示

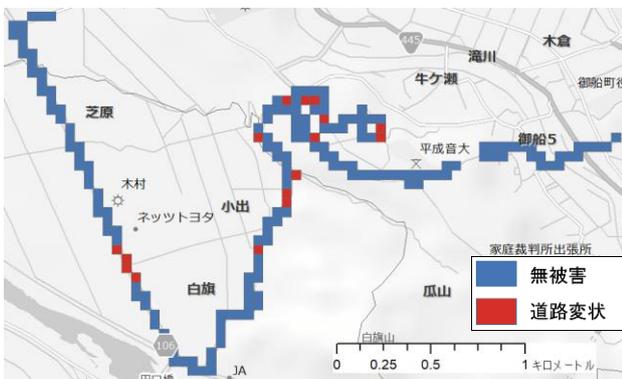


図9 ケース3の目視判読のメッシュ表示

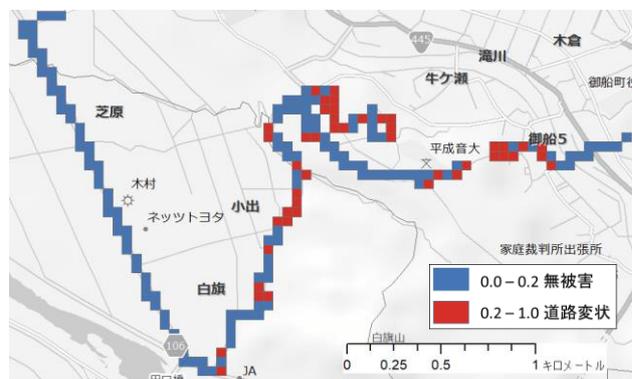


図10 ケース3の判別モデルの結果のメッシュ表示

無被害の場合は無被害メッシュとした。また判別モデルによる地図に関しては、メッシュ内の全画像数に対する道路閉塞と道路被害の和の割合によって、道路変状メッシュか無被害メッシュとした。全画像数に対する道路閉塞と道路被害の和が20.0%以上の割合であるときにそのメッシュを道路変状メッシュとすると、道路変状の検出精度は66.0%、無被害の検出精度は84.1%、全体精度76.4%と高い精度が得られた。

上記のシミュレーション手法を使用して、3 ケースのシミュレーションを行った。ケース1は2016年4月22日に熊本県益城町中央部で撮影された773枚の画像、ケース2は2016年4月25日に熊本県益城町西部で撮影された2157枚、ケース3は2016年4月26日に熊本県御船町西部およ

び甲佐町北部で撮影された1586枚を使用した。これらの画像はあらかじめ被害の有無を1人が目視判別し、判別モデルに判別させたのち、シミュレーションを行った。

図5がケース1の目視判読したもの、図6がケース1の判別モデルの結果、図7がケース2の目視判読したもの、図8がケース2の判別モデルの結果、図9がケース3の目視判読したもの、図10がケース3の判別モデルの結果である。また表2がケース1におけるメッシュ判別の精度、表3がケース2におけるメッシュ判別の精度、表4がケース3におけるメッシュ判別の精度である。

表2 ケース1のメッシュ表示の精度

		判別モデル		検出精度	全体精度
		道路変状	無被害		
目視	道路変状	57	2	96.6%	73.0%
	無被害	45	70	60.9%	

表3 ケース2のメッシュ表示の精度

		判別モデル		検出精度	全体精度
		道路変状	無被害		
目視	道路変状	128	18	87.7%	83.5%
	無被害	15	39	72.2%	

表4 ケース3のメッシュ表示の精度

		判別モデル		検出精度	全体精度
		道路変状	無被害		
目視	道路変状	9	8	52.9%	75.4%
	無被害	36	126	77.8%	

ケース1に関しては、地図左上に過剰に道路変状と判別されるエリアがあるが、そのほかは概ね正しく判別できた。誤判別が発生したエリアは生活道路などの幅員の狭い道路であり、国道などの幅員の広い道路と比較して、道路の管理水準が低く、平常時に亀裂や道路工事後の痕が残っており、これらが道路被害と誤判別されたと考えられる。その他にも電線の影が映り込み道路被害と誤判別されたケースや、路上駐車などの道路閉塞と誤判別されているケースがあった。そのため、道路変状メッシュの検出精度は96.6%と非常に高いものの、無被害メッシュの検出精度は60.9%と低い。なお、全体のメッシュ検出精度は73.0%となった。

ケース2に関しては、ほぼ正確に道路変状を判別していることがわかる。ケース2は非常に被害が大きかったエリアであり、幅員の広い道路以外では何かしらの道路変状が発生していた。全体のメッシュ検出精度も最もよく83.5%となっている。

ケース3に関しても、ほぼ正確に道路変状が発生したエリアを特定していることがわかる。しかし、幅員の広い道路では道路変状を見落としている。また、幅員の狭い道路については過剰に道路変状と判別しているエリアがある。ケース1と同様に、幅員の狭い道路において、道路閉塞、道路被害と誤判別される画像もあった。全体のメッシュ検出精度は75.4%となった。

## 5. まとめ

本研究は熊本地震後に撮影された車載カメラ画像を用いて、道路閉塞、道路被害、無被害を判別するモデルを深層学習で構築し、その精度を検証した。本研究において作成した画像判別モデルは、81.0%の判別精度であった。画像判別モデルの特徴として、概ね正しく道路状態を判別できることがわかった。しかしながら、道路被害に関しては精度が低いことがわかった。誤判別が発生するケースとして、幅員の広い道路は道路変状が発生していても無被害と誤判別されるケースが多い。幅員の狭い道路に関しては道路閉塞、道路被害と誤判別されるケースが目立った。

さらに作成した画像判別モデルを使用し、実際の使用を想定したシミュレーション手法の構築を行ったのち、3つのケースについて広域のシミュレーションを行った。実用化を想定したシミュレーションでは、地図上を50mメッシュに区切り、メッシュ内の全画像数に対する道路変状点の割合によって、メッシュ自体を道路変状メッシュか無被害メッシュに分類した。目視判別したものに関しては、この割合が0の時のみ無被害メッシュとし、それ以外を道路変状メッシュとした。判別モデルの結果については、道路変状点の割合が0.2未満を無被害メッシュとし、それ以上を道路変

状メッシュとした。判別精度は70%を超えており、概ね正しく道路変状エリアを把握できることがわかった。しかし幅員の狭い道路では50mメッシュでは大きすぎる場合や、メッシュ内の画像数が少数の場合に誤判別が発生することがわかった。

## 参考文献

- 1) 国土交通省：熊本地震による被災及び復旧状況，<http://www.mlit.go.jp/common/001135910.pdf>
- 2) 国土交通省：的確な震後対応のための被災イメージ活用と被災状況の迅速な把握技術の開発，<http://www.mlit.go.jp/chosahokoku/h17giken/program/kadai/pdf/shitei/shi2-01.pdf>
- 3) 総務省：人工知能(AI)の現状と未来，<http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h28/pdf/n4200000.pdf>
- 4) 藤吉弘亘：Gradient ベースの特徴抽出-SIFT と HOG-，情報処理学会研究報告コンピュータビジョンとイメージメディア，No. 87，pp. 211-224，2007.
- 5) 服部正志，阪柳比呂志，富川武彦：画像処理による道路表面のひび割れ検出，電子情報通信学会総合大会，D-12-95，1998.
- 6) 堀田一弘，三島健稔，栗田多喜夫：未知の画像に対する識別率を用いた顔検出のための特徴点の順序付け，電子情報通信学会論文誌 D，Vol. 84，No.8，pp.1781-1789，2001.
- 7) 久保陽太郎：ディープラーニングによるパターン認識，情報処理，Vol.54. No.5，pp.500-508，2013.
- 8) 足立吉隆，田口茂樹，弘川奨悟：ディープラーニングによる組織識別率の検証，鉄と鋼，Vol. 102，No. 12，pp. 722-729，2016.
- 9) 石井友，松岡昌志，牧紀男，堀江啓，田中聡，中村良介：現地写真の深層学習による建物被災度判定の試み，日本リモートセンシング学会第60回学術講演会，Paper No. U06，2016.
- 10) 田村誠悟，濱上知樹：深層学習を用いたモチーフ分析にもとづく小屏風画画像の特徴分析，人文科学とコンピュータシンポジウム，pp. 247-252，2015.
- 11) 全邦釘，井後敦史，南免羅裕治，黒木航汰，大窪和明：車載カメラ画像により撮影された舗装画像からのディープラーニングによるひび割れ率評価，土木学会論文集 E1 (舗装工学)，Vol. 73，No. 3，pp. I\_97-I\_105，2017.
- 12) 岡谷貴之：深層学習，講談社，2015.