

3

車載カメラ画像を活用した地震後の道路被害の自動抽出

12T0224X 瀬崎 陸
指導教員：丸山 喜久

1. 研究背景と目的

近年の我が国における震災被害は増えつつある。2016 年 4 月に発生した熊本地震は、震源に近い熊本市、益城町、西原村など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 の地震の影響で被害はより深刻化し、多数の人的被害に加えて道路被害が発生し、復旧、復興への妨げとなったⁱ。道路ネットワークは被災後の迅速な復旧活動に重要なライフラインであるため、地震後早期に道路状況を把握する必要がある。現在、道路被害を確認する方法は、自治体職員による目視調査が中心であり、時間を要し、職員への負担も大きい。

近年、画像認識の分野で深層学習(ディープラーニング)と呼ばれる機械学習法が注目されているⁱⁱ。機械学習は従来の機械学習法を上回る精度を記録しており、写真から道路被害の有無の認識をすることによって、災害発生時の自治体職員の負担を減らすと考えられる。

そこで本研究では、4 月 17 日、20 日に熊本地震の被災地である益城町など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を作成した。その判別モデルを用いて、判別モデル作成時には使用しなかった画像を判別させ精度の検証を行った。

2. ディープラーニングに基づく学習の流れ

本研究では車の正面から撮影した連続写真に被害の有無をラベル付けしたデータセットを作成し、深層学習による学習を行った。

(1)対象地域と使用データ

本研究の対象地域は熊本県益城町周辺であり、熊本地震発生後の 4 月 17 日と 4 月 20 日にグローバル・サーベイ株式会社によって撮影されたものを使用した。車載カメラの画像(図 1)を、被害あり、無被害に目視によって分類し、それらを 256×256 ピクセルに解像度を変更した後に正規化した。

被害あり、無被害ともに、4 月 17 日に撮影された画像を中心に教師用画像 764 枚ずつ合計 1528 枚を学習用とした。精度検証用の画像として、4 月 20 日に撮影されたものを中心に、被害あり 560 枚、無被害を 560 枚を準備した。

(2)使用フレームワーク

本研究では、深層学習のフレームワークとして Caffe を使用した。また、ネットワークの構成には、リファレンスモデルの cifar10 の一部改変させたも



図 1 車載カメラ画像の例

の、プログラミング言語は python を用いた。計算には GPU を使用し高速化を図った。

3. ディープラーニングのパラメータ

(1)学習率ⁱⁱⁱ

ニューラルネットワークの重みの最適化には以下の勾配法を利用する。

$$x_{i+1} = x_i - lr \frac{\partial f}{\partial y} \quad (1)$$

式(1)での lr は学習率、 x_i はある時点での変数の値で

あり、 $\frac{\partial f}{\partial y}$ は勾配、 x_{i+1} は次の変数の値、 f は損失関数である。

(2)学習回数

判別モデルをディープラーニングによって作成する際、何回学習を実行させるかは重要なパラメータの一つである。一般に学習回数を増やせば増やすほど精度は向上するため数万回行うこともあるが、モデルによっては学習しすぎると過学習になり汎用性が落ちる。本研究では教師用画像の枚数が少ないため計算回数を増やしても、精度に変化はほとんど見られない。そこで cifar10 を参考にして、本研究では 4000 回とした。

(3)ネットワークの階層数^{iv}

本研究では cifar10 のモデルを使用している。畳み込み層が 3 層、プーリング層が 3 層、全結合層が 2 層という構造である。

(4)画像の切り取りかた

実験に使用した車載カメラ画像の上半分は空や雲が映っていることが大半である。空や雲が写り込んでいる写真をディープラーニングすると、空や雲の形なども結果に影響を与えるのではないかと考え

たため、切り取りをしない、画像の下半分のみ使用、画像の下四分の一のみ使用の三種類を用意した。

4. 計算条件と結果

本研究では、判別モデル作成時に教師用画像 1528 枚を訓練用とテスト用に 6:1 の比率で分け、学習率と画像の切り取り方の組み合わせを変化させてディープラーニングを実施した。また学習回数を 4000 回とし、訓練時の損失関数 (train_loss) (訓練時にニューラルネットワークが見つけたアルゴリズムの正さを評価する指標であり、アルゴリズムが正しいほど 0 に近づく) を 100 回毎、テストの正確性 (test_accuracy) (アルゴリズム作成時に使用していないテスト用画像が正確に判別できた割合) と損失関数 (test_loss) (テスト時にニューラルネットワークが見つけたアルゴリズムの正さを評価する指標であり、アルゴリズムが正しいほど 0 に近づく) を 500 回毎に表示させた。

完成した判別モデルに、検証用画像としてあらかじめ目視によって分類した被害あり 560 枚、無被害 560 枚を判別させその正確性を検証した。12 個の判別モデルの作成したところ、学習率 0.0005、画像を下四分の一のみ使用したモデルが最もよく、72.9% の正答率となった (図 2, 表 1)。




図 2 損失関数と正確性

表 1 判別結果

		目視で判別	
		被害あり	無被害
判別モデルの結果	被害あり	447	190
	無被害	113	370

5. 考察

学習率 0.01 の時はすべてのケースで判別モデルの作成に失敗した。このことから学習率は 0.01 より小さい値でないと計算ができない。また学習率が小さ

すぎても学習の精度が落ちることがわかった。その画像のデータセットに応じた学習率を探っていく必要がある。画像の切り取り方については、判別に必要な部分のみを残し、それ以外は切り取って判別を行うことが重要であることがわかった。

さらに、本研究では、判別モデルが「被害あり」または「無被害」と判断する際に、その確率も算出している。「被害あり」にも関わらず「無被害」と判断した画像は 113 枚あり、その中でも無被害の確率を 100%とした画像は 10 枚存在した。同様に「無被害」にも関わらず「被害あり」と判断した画像は 190 枚あり、その中でも被害ありの確率を 100%とした画像は 33 枚存在した。



図 3 被害ありの確率 1 の画像例

それらを検証すると、今回のモデルに足りないものは、対向車の認識、電柱の影の認識、地震以外で発生した道路の亀裂、ある特徴をもつ被害の認識、教師用画像を選ぶ際の見落としであると考えられる。これらを改善するためには、教師用画像の数を増やすこと、できるだけ正確に目視で判別することが必要である。さらには、ニューラルネットワークの層の数を増やすことによって、さらに細かい道路上の変化を認識できると考える。このほかにも、学習回数、学習率、バッチサイズ、活性化関数などの値を変化させながら、最適なモデルを作成していく必要がある。

6. 今後の展望

より現実的なモデル作成のために、現在は道路閉塞、道路被害を「被害あり」とまとめてしまっているものを、「道路閉塞」、「道路亀裂」、「建物倒壊」など選択肢を増やす必要がある。さらに、本研究では、熊本地震発生直後の 4/17、4/20 の車載カメラ画像全 20852 枚を使用した。本研究では扱い切れなかった、4/22、4/23、4/25、4/26、4/28、の画像全 440,298 枚が存在する。これを今後の研究に使用していけば、さらなる精度の向上が見込まれる。

ⁱ 気象庁：地震被害のページ：<http://www.data.jma.go.jp/svd/eqev/data/higai/higai1996-new.html>

ⁱⁱ 武井宏将：初めてのディープラーニング，リックテレコム，2016

ⁱⁱⁱ 岡谷貴之：深層学習，講談社，2015.

^{iv} Deep Learning ハンズオン勉強会：<http://www.slideshare.net/yasuyukisugai/deep-learningcaffe>