車載カメラ画像を活用した地震による道路被害の抽出に向けた基礎検討

千葉大学大学院融合理工学府　学生会員　○瀬崎陸，正会員　丸山喜久
鹿島技術研究所　正会員　永田茂

１．研究背景と目的

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，道路管理者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．

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，深層学習に基づく被害有無の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．使用したデータと深層学習のフレームワーク

本研究では自動車の正面から撮影した連続写真に道路被害の有無をラベル付けしたデータセットを作成し，深層学習に基づく判別モデルを構築した．

(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．車載カメラの画像を，被害ありと無被害に目視で分類し，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，主に 4 月 17 日に撮影された画像から教師用画像を 764 枚ずつ選定し，これを学習用データとした．精度検証用の画像には，主に 4 月 20 日に撮影されたものから，「被害あり」と「無被害」をそれぞれ 560 枚選定した．

(2)　深層学習のフレームワーク

本研究では，深層学習のフレームワークとして Caffe[ii]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 CIFAR-10 の一部改変させたもの，プログラミング言語は Python を用いた．学習には GPU を使用し高速化を図った．

３．深層学習のパラメータ

(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．

$$\theta_{i+1} = \theta_i - lr\nabla_\theta J(\theta) \quad (1)$$

ここで，lr は学習率，θ_i はある時点での重みであり，$J(\theta)$は損失関数である．本研究では，0.1, 0.001, 0.0005, 0.0001 の 4 種類を仮定した．

(2)ネットワークの階層数[iv]

本研究では CIFAR-10 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．

(3)学習用画像の設定

車載カメラ画像の上半分は空や雲が占めている．空や雲が写り込んでいる写真で深層学習を行うと，空や雲の様子が結果に影響を与えることもあり得るため，画像をそのまま用いる場合，画像の下半分のみ使用する場合，画像の下四分の一のみ使用する場合の 3 通りで学習を実行した．

４．学習条件と判別精度

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，学習率と画像の設定の組み合わせを変化させて深層学習を実施した．学習回数を 4000 回とし，訓練時の損失関

key words 平成 28 年熊本地震，ディープラーニング，車載カメラ画像，
連絡先: 〒263-8522 千葉県千葉市稲毛区弥生町 1-33 千葉大学大学院融合理工学府地球環境科学専攻都市環境システムコース
TEL 043-290-3555

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し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．12 個の判別モデルを検討したところ，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精度の高いモデルとなった（図 1，図 2）．

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．本研究の判別モデルの正答率は 72.9%となった（表 1）．

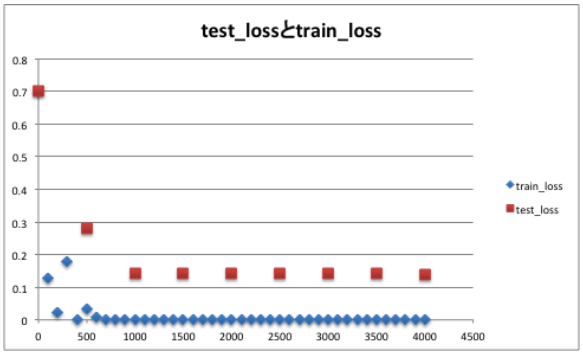

図 1　判別モデルの損失関数

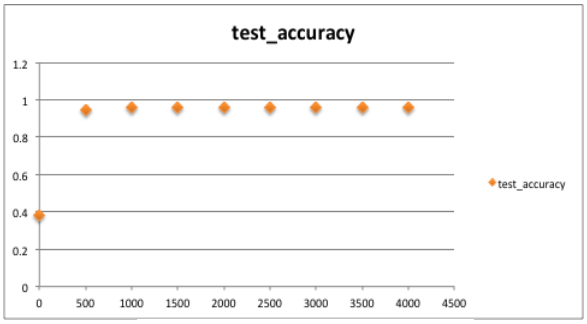

図 2　判別モデルの正確性

表 1　検証用画像の判別結果

		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．判別結果の考察と今後の課題

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 より小さい値である必要がある．また学習率が小さすぎても学習の精度が落ちることがあった．画像の設定については，道路被害の判別に必要な部分（画像の下四分の一）のみを残し，それ以外は切り取って学習させると精度が高くなった．

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，そのうち「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，そのうち「被害あり」の確率を 100%とした画像は 33 枚存在した（図 3）．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．

図 3　無被害にもかかわらず被害ありの確率が 100%とされた画像の例

判別モデルを改善するためには，教師用画像の数を増やすことと，学習時の教師用画像データを精査することが必要である．本研究では，熊本地震発生直後の 4 月 17 日，4 月 20 日の車載カメラ画像全 20,852 枚を使用したが，それ以降に取得された画像を検討に加えれば，さらなる精度の向上が見込まれる．また，ニューラルネットワークの層数を増やすことによって詳細な被害判別が期待されるが，この際には学習回数，学習率，バッチサイズ，活性化関数などを変化させながら，最適な判別モデルを構築する必要がある．さらに，現在は道路閉塞，道路被害を単に「被害あり」としているが，被害形態を「道路閉塞」，「道路亀裂」，「建物倒壊」など複数に分けることも必要と思われる．

[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 Learining ハンズオン勉強会：http://www.slideshare.net/yasuyukisugai/deep-learningcaffe