

被災がれき量推定に向けた画像解析を利用した倒壊建造物の自動抽出 Automatic Detection of Collapsed Buildings using Image Analysis for Estimating Disaster Debris Amount

利根川 凜[†] 飯塚 博幸[†] 山本 雅人[†] 古川 正志[‡] 大内 東^{*}
Rin Tonegawa Hiroyuki Iizuka Masahito Yamamoto Masashi Furukawa Azuma Ohchi

1. はじめに

東日本大震災に代表される津波を伴う大規模な家屋倒壊を含む災害時において、被災地の早期復旧には、発生した災害廃棄物の処理を迅速に行う必要がある。特に、被災がれき処理では、有効な処理計画立案のため、発生する被災がれき量の早期把握が必要となる。処理計画が有効であれば、無駄のない予算組みや運用が可能となり、被災地の早期復旧への貢献が期待できる。

しかしながら、現在、被災地から災害直後に得られる情報は乏しく、被災地の被害状況把握は困難である。よって被災地から得られる数少ない情報を活用し、すばやく被害状況を把握する手段の確立が望まれる。本研究では、被災地上空で撮影される航空写真に着目し、建造物倒壊により発生する災害廃棄物量(被災がれき量)推定のための倒壊建造物の自動抽出手法を検討する。具体的には、震災前後の被災地の航空写真に対し、畳み込みニューラルネットワークを用いた学習により、倒壊建造物の自動抽出を行う。

2. 関連研究

能島らは、地震動情報やフラジリティ関数などを組み合わせた早期被害推定結果を一次情報、リモートセンシングから把握される被害地域の情報を二次情報、実際に被災地への立入り調査で得られる情報を三次情報とおき、被害情報を逐次更新するシステムを提案している¹⁾。しかしながら、三次情報の取得については、被害が広域になるにつれ、被災地の被害情報の確認、および、収集に多大な時間が必要となる。そこで、航空写真やハザード情報を活用し、被害状況をリモートセンシングから高精度に把握すれば、復旧への意思決定が三次情報を待たずに可能となる。本研究では、二次情報となる自動かつ高精度に被害状況を推定する手法を提案する。関連研究として、平山らは、地理情報システムを用いて津波浸水域を同定し、津波浸水による住家被害テーブルを用いた災害廃棄物量の推定を提案している²⁾。ただし、地域メッシュ別の津波浸水を把握するには、詳細な津波再現計算や浸水深に関する調査が必要となり、詳細な被害状況の推定や、被害が広域な場合、短時間での被害推定は困難となる。この問題を解決するため、本研究では短時間でより詳細な災害廃棄物量の推定を目指す。具体的には、被災地の航空写真を一定地域ごとに解析し、建造物ごとに倒壊の有無を判別する手法を提案する。

3. 提案手法

本研究では、震災前後の被災地航空写真、および、被災地建造物の大きさと位置を参照可能な地図データを利用し、以下に示す手法により、建造物の倒壊判別を行う。

[†]北海道大学 Hokkaido University

[‡]北海道情報大学 Hokkaido Information University

*東北大学 Tohoku University

- (1) 画像データ取得
- (2) 航空写真内の注目建造物のトリミング
- (3) 畳み込みニューラルネットワークによる判別

3.1. 被災地空撮画像内の注目建造物のトリミング

本研究で使用する航空写真内の建造物は、地図データ上でも同位置に該当建造物が存在する。地図データは建造物の位置と大きさを参照でき、地図データから建造物について一戸ずつ注目し、被災地航空写真上で同一座標の位置、および、大きさを切り出せば、注目建造物のトリミングが可能となる。

3.2. 畳み込みニューラルネットワークによる判別

従来の画像認識では、事前に認識対象を判別する特徴量を抽出し、教師あり学習を行う。そのため、高い認識精度を得るためには、有効な特徴量の設定が必要となる。一方で、畳み込みニューラルネットワーク(以下 CNN)は、畳み込み層、プーリング層を交互に接続した構造を持ち、ネットワーク内で特徴量抽出フィルタを学習する。そのため、対象物の認識を決定付ける有効な特徴量を設計者が定義する必要がなく³⁾、高い認識性能を得られる。倒壊建造物の抽出では、被災地建造物の大きさや形状等の状態が多岐にわたり、特徴量抽出、および、設定が困難となるため、CNNを用いた倒壊建造物の自動抽出を行う。

本研究で使用する畳み込み層は式(1)、(2)で定義する。

$$y_{ijkl} = \sum_{c=1}^N \sum_{p=1}^m \sum_{q=1}^m x_{(i+p)(j+q)c} W_{pqcl} + b_l \quad (1)$$

$$y_{ijkl} = \tanh(y'_{ijkl}) \quad (2)$$

式(1)は x を入力画素、 W を重み、 b をバイアスとした際に $m \times m$ サイズのフィルタを用い、 N チャネルの画像を入力した際の出力 y' である。 y' を式(2)の活性化関数で次の層に与える出力に変換する。

プーリング層では、畳み込み層で出力された画像の解像度を下げ、入力画像間の微小な差に対する応答の普遍性を実現する。本研究では、畳み込み層で出力された画像の一部の小領域について、最も y の高い値を用いる。

CNN の出力層付近では全結合層を配置する。全結合層は、畳み込み層とプーリング層で得られた特徴をもとに、画像の判別を行う。最後の出力は分類クラス数と同数のユニットを配置し、ソフトマックス関数を用い、出力とする。

4. 数値計算機実験

震災前後での倒壊建造物自動抽出の精度検証のため、本研究では震災後の航空写真を使用する場合と震災前後の航空写真を使用する場合を比較する。震災前後を使用する場合は2枚の写真の比較ができるため、より精度の良い認識が期待できる。また、震災前の航空写真が震災後の倒壊と



図1 震災前の航空写真 図2 震災後の航空写真

Copyright ©NTT 空間情報 All Rights Reserved

非倒壊の判別に関してどの程度の情報を持っているかを評価するために震災前の航空写真を使用した場合も行った。

4.1. ネットワークの設計

本研究で使用するネットワークは 8 層で構成する。畳み込み層を C1, C2, プーリング層を P1, P2, 全結合層 N1, N2 とし, C1, P1, C2, P2, N1, N2 の順に配置する。以下, CNN のパラメータを表 1 に示す。入力チャンネル数は, 判別器に震災前後どちらかを入力する場合は 1 チャンネル, どちらも入力する場合 2 チャンネルとする。また, バッチサイズ 4, 学習率 0.01, 学習回数 200 回と設定する。

4.2. 使用画像データの設定

東日本大震災被災地の岩手県釜石市の航空写真について, 以下の条件の画像を使用する。震災前は 2008 年 11 月撮影 (図 1), 震災後は 2013 年 4 月撮影 (図 2) であり, 縮尺はいずれも 2500 分の 1 であり, 株式会社 NTT 空間情報から提供されている。地図データは東日本大震災復興支援調査アーカイブ⁴⁾の位置や形状情報を利用する。

CNN に入力する訓練データとテストデータの建造物は, 震災前の航空写真で建造物の全体像が鮮明に写っている 75 件とする。CNN の学習は過学習を避けるため大量の画像データが必要であるので, 75 件の建造物を上下左右反転し, 建造物を 300 件用意した。うち 200 件を訓練データ, 100 件をテストデータと定義する。更に訓練データは, 画像内に白と黒の矩形ノイズをランダム表示させ, 2000 件とする。

4.3. 正当性の評価指標

判別器の正当性の検証のため, 判別対象の建造物が震災前後で実際に倒壊したかは, 予め目視で判別する。本来建造物が存在する場所に注目した際, 震災前後の航空写真上で実際に該当建造物が存在するか 1 件ずつ調査する。震災前に建造物が存在したが, 震災後には建造物が存在しない例を倒壊, 震災前後どちらも確認出来た例は非倒壊とする。

5. 実験結果

200 試行後に各判別器に各訓練データを入力すると, 全判別器で正答率 100%であった。最も精度の良かった判別器は震災後の航空写真のみで判別器を作成した場合で正答率 86%であり, 震災前後の航空写真で作成した判別器の正答率は 83%であった。図 3 は, 震災後の航空写真の判別器の正答率の推移である。震災後の航空写真での判別器の判別失敗例は, 100 件中 14 件であった。正解は倒壊だが判別器が非倒壊とした例は 14 件中 4 件で, 画像内に近隣の建造物が大きく存在するため, 近隣の建造物で判別された可能性がある。一方, 正解は非倒壊だが判別器が倒壊とした 10 件は, 建造物の屋根が影と誤認識されうる例だった。

震災前後の航空写真から作成した判別器での失敗例は 100 件中 17 件, 正解は倒壊だが判別器が非倒壊とした例は震災前後で画像に差があれば, 倒壊と判別される。実際に, 震災後データの判別器で正解は倒壊だが判別器が非倒壊と誤答した 4 件は, 震災前後の判別器では倒壊と判別し, 正解している。

表 1 CNN の各層のパラメータ設定

	縦×横×チャンネル	フィルタサイズ
入力	180×192×1 or 2	—
C1	176×188×10	5×5
P1	88×94×10	2×2
C2	84×90×20	5×5
P2	28×30×20	3×3
N1	1×1×100	1×1
N2	1×1×2	1×1
softmax	1×1×2	1×1




図3 震災後の判別器での正答率の推移

また, 震災前の航空写真のみで判別器を作成し, 震災前テストデータで判別する場合は正答率 49%であった。すなわち震災前の航空写真のみでは, 倒壊建造物抽出のために有用な情報は一切持たない。本研究では, 震災前後両方の航空写真の情報を学習した倒壊建造物抽出を期待したが, 震災前後での差分等を効果的に活用した高い判別結果は得られなかった。ただし, 本研究での使用航空写真は震災前後の撮影間隔が約 5 年と長期であり, 撮影時期の大きな時間差から画像が効果的に比較できなかった可能性がある。そのため, 震災直前, および, 直後の航空写真が入手できれば, 更なる精度向上が期待できる。また, 震災後の航空写真は東日本大震災後約 2 年経過したデータであった。そのため, 倒壊建造物周辺の土砂や汚泥などは既に整地されている。そのため, 震災直後の航空写真があれば, 倒壊判別の精度向上が見込める情報が更に得られる余地がある。

6. おわりに

本研究は東日本大震災での被災地航空写真を用い, CNN を利用した倒壊建造物の抽出を行った。特に, 震災後の航空写真から作成した判別器は 86%の正答率を得た。予備実験で線分等の画像特徴量を利用した場合正答率は約 67%であり, CNN による画像判別がより簡便かつ高精度な手段であった。震災後の救援活動には, 被害分布の概要を早期把握が必要である。本手法を広域に適用し, 抽出した倒壊建造物の面積から, 迅速ながれき量推定が望まれる。

参考文献

- [1] 能島暢呂, 杉戸信太, 金澤伸治, 被害情報の逐次処理による地震時緊急対応の意思決定支援モデル, 土木学会論文集, No. 682/I-56, pp. 129-142 (2001).
- [2] 平山修久, 河田恵昭, 奥村与志弘, 東日本大震災における災害廃棄物量の推定と災害対応, 廃棄物資源循環学会誌/論文誌, Vol. 23, No. 1, pp. 3-9 (2012).
- [3] 岡谷貴之, 画像認識のための深層学習, 人工知能学会誌, 28 巻 6 号, pp.962-974 (2013)
- [4] 国土交通省都市局, 東日本大震災復興支援調査アーカイブ, <http://fukkou.csis.u-tokyo.ac.jp/>