

現地写真を用いた畳み込みニューラルネットワークによる建物の被災度判別

千葉大学 学生会員 ○戸澤 謙弥
 千葉大学 正会員 劉 ウェン
 千葉大学 正会員 丸山 喜久

1. はじめに

地震をはじめとした自然災害の発生後、被災地やその周辺の自治体職員等によって、被災した建造物の被害程度を把握するための調査が実施される。その一つとして、内閣府の定める基準に基づき実施される被害認定調査がある。この調査では、外観目視を基本とした第1次調査や、必要に応じて内観等を含む詳細な調査を実施し、建物の被害を5段階で評価する。得られた調査結果は、罹災証明書として被災者に交付され、被災者支援措置に活用される。

しかしながら、このような調査は災害の規模は大きく被災範囲が広範囲に及ぶと、調査対象となる建物が急増することから、人員不足に伴う調査時間の遅延などが問題視されている。2016年に発生した熊本地震を例に挙げると、地震発生から1ヶ月の時点で、罹災証明書の申請件数に占める交付数の割合は3割程度に留まっており、証明書発行の遅れが問題となった。

そこで本研究では、建物の被災度を判別するために行う被害認定調査の効率化を目的として、建物の外観画像データに畳み込みニューラルネットワーク(CNN)を適用した建物の被災度判別を試みる。

2. CNNと使用データの概要

CNNは全結合層のみで構成される多層ニューラルネットワークとは異なり、畳み込み層やプーリング層と呼ばれる層を持つことが特徴である。本研究では、複数のCNNとデータセットを用いて学習結果を比較することで、被災度判別により適したモデルの構築を目指す。使用したCNNの一つを図2-1に示す。

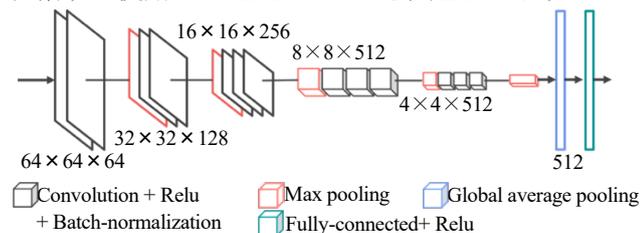


図2-1 CNNの構成例

CNNの中間層において多く利用されている畳み込み層では、カーネルと呼ばれる重みパラメータを保持する積分核を用いて、畳み込み処理が行われる。この層には一般的に、様々なバリエーションのカーネルが存在し、カーネルの数だけ特徴マップと呼ばれるテンソルが出力される。

その後、プーリング層にて、入力画像の注目領域における最大値を、特徴マップの出力値とする処理がなされる。この処理により、データサイズの削減や、領域内の特長をロバストに取得することができる。

また、CNNにおける重みの学習にはNesterovの最急勾配法¹⁾を使用した。この更新則は、最急降下法の更新式に慣性による更新式(1)を加えることで、学習の効率化を実現したMomentum法から派生した手法である。具体的には、更新前の出力値 x_t に対し、学習率 η 及び $0 \sim 1$ の任意定数 γ を設定し、以下の更新式(2)を適用することで、更新後の出力値 x_{t+1} が得られる。

$$v_t = \gamma(x_t - x_{t-1}) \quad (1)$$

$$x_{t+1} = x_t + v_t - \eta \nabla f(x_t + v_t) \quad (2)$$

この更新則の特徴として、勾配の更新時に慣性による更新式(1)を引数に入れていることが挙げられる。様々な更新則同じデータセットに対して学習を行ったところ、この更新則を用いた際に最も高い精度が得られたことから、本研究ではこれを用いることとした。

本研究では、熊本県益城町、宇城市、熊本市を対象に、2016年の熊本地震発生後に実施された被害認定調査の際に撮影された現地写真を用いて、データセットを作成した。図2-2に被災度別の建物全体画像の例を示す。

画像例					
被災度	全壊	大規模半壊	半壊	一部損壊	無被害

図2-2 被災度別の建物全体画像の例

キーワード 深層学習, 画像認識, 建物被害, 現地写真, 2016年熊本地震

連絡先 〒263-8522 千葉県千葉市稲毛区弥生町1-33 千葉大学大学院工学研究院 TEL:043-290-3555

3. データセットの詳細と学習条件について

本研究では、被害認定調査の第1次調査のうち、建物被害を全壊か否か目視で判定する外観による判定ⁱⁱ⁾をCNNで補完することを目的とする。そのため、第1次調査にて全壊判定がなされた建物画像をクラス1、それ以外の判定がなされた建物画像をクラス2としたデータセット1と、クラス2を一部損壊、または無被害判定がなされた建物画像のみで構成したデータセット2を作成し、2クラス分類を行う。なお、クラス2には異なる被災度判定がなされた建物画像が混在しているが、クラス1の画像データ数と差異が生じないように、被災度別に分けられた建物画像群から無作為に抽出しデータセットを構築している。

さらに、画像データは、事前に64×64pixelにリサイズした上でグレースケール変換を行う。また、訓練データは、鏡像反転と回転処理を施し、元の画像の4倍の枚数に拡張したものを使用する。今回は訓練データとテストデータの構成比を8:2とし、訓練画像4772枚、テスト画像を1194枚に対して計算処理を行った。CNNの学習条件と各種パラメータを表3-1に示す。

表3-1 CNNの学習条件

活性化関数	Relu (中間層)
	Softmax with Loss (全結合層)
パラメータ更新則	Nesterovの加速勾配法
ミニバッチサイズ	64
学習回数	30000
学習率更新則	Multi-step
学習率初期値	0.1
Weight Decay	0.0001 (default)

4. 学習結果

図2-1に示したネットワークと表3-1に示した学習条件に基づき、構成の異なる2つのデータセットを適用して得られた結果を表4-1に示す。さらに、データセット別の訓練データ及びテストデータの正答率推移を図4-1、4-2に示す。

表4-1 データセット別の学習結果

	データセット1	データセット2
Accuracy[%]	69.0	77.8
Loss	2.07	1.28

*表中の数値は計算回数30000におけるテスト結果

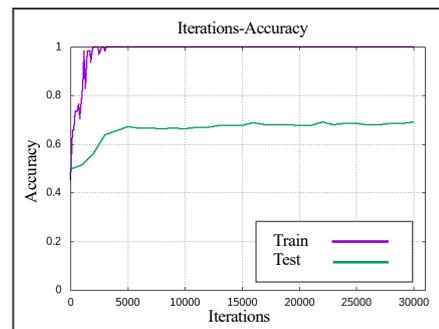


図4-1 データセット1使用時の正答率の推移

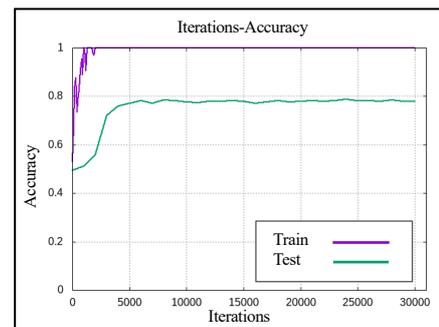


図4-2 データセット2使用時の正答率の推移

5. 考察

2つのデータセットを使用して検証を行ったところ、データセット2を用いて学習を行った際の正答率がより高い結果となった。このことから、大規模半壊及び半壊判定がなされた画像群には、全壊と判別され得る建物画像が多く含まれていることが分かる。

一方で、図4-1、4-2より、訓練データとテストデータの正答率推移が僅かに乖離していることから、過学習の恐れがある。過学習の発生要因を鑑みると、データ数の不足によるものと考えられる。

6. 結論と今後の展望

今回作成したモデルによって、全壊建物を8割近い精度で抽出することができた。今後は、過学習の発生を抑制するため、他市町村の画像データを随時追加していくことで、より汎化性能の高いモデルの作成を目指す。また、より詳細な被災度判別を実現するため、建物の部位（屋根・外壁・基礎）ごとに損傷率を算出した上で、判別を行うモデルの検討も進めていく。

謝辞

本研究は、首都圏を中心としたレジリエンス総合力向上プロジェクトの一環として行ったものである。記して、謝意を表する。

ⁱ⁾ Y. Nesterov: A method of solving a convex programming problem with convergence rate $O(1/k^2)$, Soviet Mathematics Doklady, 27, pp. 372-376 (1983).

ⁱⁱ⁾ 内閣府：災害に係る住家の被害認定, <https://www.bousai.go.jp/taisaku/unyou.html>